

# 基于神经网络-证据理论的遥感图像 数据融合与湖泊水质状况识别

石爱业<sup>1)</sup> 徐立中<sup>1)</sup> 杨先一<sup>1),2)</sup> 黄凤辰<sup>1)</sup>

<sup>1)</sup> (河海大学计算机及信息工程学院, 南京 210098)

<sup>2)</sup> (Guelph 大学工程学院机器人与智能系统实验室, Guelph, 加拿大)

**摘 要** 为了进一步提高湖泊水质状况识别的准确性,提出了一种基于神经网络-证据理论的遥感图像数据融合处理方法,并以太湖水水质监测数据为例进行了实证分析。该方法先对不同的遥感输入图像,采用各自相应的神经网络进行处理,然后对神经网络输出的结果做归一化处理,再利用 D-S 证据理论进行数据融合,最终给出水质的识别结果。该方法的优点为(1)可增加水质识别的容错性;(2)由于融合了多源水质遥感图像的数据,因而水质状况识别的可信度更高。

**关键词** 遥感图像 水质识别 数据融合 D-S 证据理论 BP 神经网络

**中图法分类号:** TP751.1 X824 **文献标识码:** A **文章编号:** 1006-8961(2005)03-0372-06

## Remote Sensed Images Fusion and Lake Water Quality Identification Based on Neural Networks and Evidence Theory

SHI Ai-ye<sup>1)</sup>, XU Li-zhong<sup>2)</sup>, YANG Xian-yi<sup>1),2)</sup>, HUANG Feng-chen<sup>1)</sup>

<sup>1)</sup> (College of Computer and Information Engineering, Hehai University, Nanjing 210098)

<sup>2)</sup> (Advanced Robotics and Intelligent Systems Laboratory School of Engineering, University of Guelph, Guelph, Canada)

**Abstract** In order to identify the lake water quality accurately, this paper presents a method for remote-sensed image fusion based on neural networks and evidence theory. This method firstly employs a neural network for each remote-sensed image and then normalizes the output of neural networks. After that, D-S evidence theory is used to fuse with results from all the neural networks, resulting in the water quality evaluation. The proposed method is applied to the water quality of Taihu lake. The developed approach to water quality identification has the two features: (1) low fault tolerance; and (2) high reliability as multi-source water-quality data are fused.

**Keywords** remote-sensed image, water quality identification, data fusion, D-S evidence theory, neural networks

## 1 引 言

在湖泊水质监测及水质状况识别中,基于地面监测的传统方法,虽然具有监测水质参数广的优点,但是易受人力、物力和气候、地形、水文等条件的限制,而且存在地面监测站布设的经验性和监测船在水面上行进时,破坏了监测区域的水质状况等缺点,难以实现连续、快速的监测,而遥感监测,由于具有

观测范围广、观测周期短、数据时效性强、全天候及动态监测等优点,因此对传统的地面监测方法是一个有效的补充。

利用遥感进行水质监测及水质状况识别,从本质上来说,是一个不确定性问题,因为遥感数据与地面监测的水质参数及状况之间的回归模型常常难以确定,需要大量的试验。神经网络模型是一种有效的非线性逼近方法,其虽能较好地实现从输入到输出状态空间的非线性映射<sup>[1]</sup>,但是采用神经网络模

**基金项目:**国家自然科学基金项目(60374033);江苏省自然科学基金项目(BK2002064)

**收稿日期:**2004-08-11;改回日期:2004-12-13

**第一作者简介:**石爱业(1969~),男,2002年获南京理工大学光学工程专业硕士学位,现为河海大学讲师。目前从事信息处理、信息融合等方面研究。E-mail: shiaiye@sina.com; lzhu@hhu.edu.cn

型时,却要求有足够多的且正交完备的训练样本集,由于地面监测点的数量总是有限的,从而导致经训练后的神经网络模型推广性能变差。虽然 Kenier 所采用的交叉训练的方法,使神经网络的推广性能有所提高,并可以在一定程度上提高水质监测的可信度<sup>[2]</sup>,但是仅通过对单一结构的神经网络模型本身的改进,仍较难从根本上解决问题。

由于水环境信息关联性强、复合因素多,且水质参数及状况专题信息提取的难度高,因此单靠一个遥感图像的监测信息是不完全的、不一致的<sup>[3]</sup>。改进的方法是先采用多光谱、雷达等多遥感图像数据来进行数据融合处理,再依据融合的结果进行水质识别。Zhang 联合应用 TM 遥感图像和 ERS-2 SAR 图像进行数据融合处理,其建立的 BP 神经网络的输入为 7 个 TM 波段数据和 SAR 数据,输出层为叶绿素  $\alpha$ 、悬浮物等具体的水质参数<sup>[4]</sup>,但该文对 TM 图像和 SAR 图像数据的融合处理仍采用的是单一结构的神经网络模型。林志贵、徐立中等将 Dempster-Shafer(D-S)证据理论方法应用于水质监测与评价中<sup>[5]</sup>,提出了一种多源水质监测数据融合处理评价模型,他们所做的实验工作是采用长江口水文站水质监测数据来对水质状况进行识别。

本文在对上述文献进行研究的基础上,提出了一种基于神经网络-证据理论的遥感图像数据融合处理方法,并将其用于湖泊水质状况识别。本方法先对不同的遥感输入图像,采用各自相应的神经网络进行处理,并实现神经网络从各自输入的遥感图像到输出水质状况的映射;然后对各自遥感图像的神经网络输出的结果做归一化处理,再利用 D-S 证据理论进行融合,最终给出水质的状况。

## 2 基于神经网络-证据理论的遥感图像数据融合与湖泊水质状况识别方法

本文方法的系统结构框图如图 1 所示,其主要由神经网络部分和 D-S 证据推理部分组成,其中神经网络主要实现遥感图像数据与水质类别之间的映射,即先初步判别水质类别,形成  $n$  个证据,然后输入给 D-S 证据推理部分,再依据证据组合规则,来得到最终的水质类别。

本方法的优点为:

(1)可利用多个遥感图像,融合处理多个传感器在空间和时间上的冗余或互补信息,使水质判别




图1 水质状况识别方法的系统结构框图

Fig. 1 Block diagram of water quality identification

的结果更准确,可信度更高。

(2)湖泊水质类别的数目一般是 5~8 类,由于本方法一般采用的遥感图像数目为 2~4 个,所以证据组合的计算量不会呈指数级增长。

### 2.1 神经网络

对于神经网络模型的选择,尽管 BP 神经网络有一些固有的缺点,但是由于 BP 神经网络是全局逼近算法,因而 BP 神经网络具有较好的推广性能。由于 BP 神经网络的神经元采用的传递函数通常是 Sigmoid 型可微函数,所以可以实现输入和输出间的任意非线性映射。在本方法中, $n$  个神经网络都采用 BP 神经网络。另外,因为一般 3 层的网络就可以实现任意非线性映射,所以本文的 BP 神经网络选择 3 层(即输入层、隐层和输出层),其中,由于每个遥感图像的光学性质不同、波段不同,所以每个 BP 神经网络的输入层的神经元数目可由所采用的具体遥感图像确定,隐层的神经元数目可在网络训练过程中确定,而输出层的神经元数目则根据水质类别的编码确定。

在本方法中,神经网络主要是用来获取水质类别的证据,尽管为了使获取的证据可信度更高,神经网络要求有大量样本的学习,但由于实际情况是用于水质监测点的数量总是受限制的,因而导致用来训练 BP 神经网络的样本偏少,为了使神经网络的推广性能较好,本文采用交叉训练的方法<sup>[2,6]</sup>,即先把有限的样本集随机地分为训练集和验证集,且训练集的数目要多于验证集的数目,然后利用这些不同的训练集和验证集来训练神经网络,最后通过比较,找出训练误差最小的网络结构作为最终的 BP 神经网络结构。

### 2.2 证据理论

证据理论以其在不确定性的表示、量测和组合等方面的优势而广泛应用于数据融合、模式识别、故障检测、人工智能等领域。

#### 2.2.1 D-S 证据理论基本概念

(1) 定义  $\theta$  为辨别框,  $2^\theta$  为由  $\theta$  的所有子集构成的集合, 其基本概率分配 BPA (basic probability assignment) 为  $2^\theta \rightarrow [0, 1]$ , 它表示给定证据时, 所提供假设  $A$  的精确信任的部分。命题的信任函数 (belief function)  $b$  表示对  $A$  的全部信任, 而似真函数 (plausibility function)  $S$  则表示对  $A$  非假的信任:

$$b(A) = \sum_{B \subseteq A} m(B) \quad (1)$$

$$S(A) = \sum_{B \cap A \neq \emptyset} m(B) \quad (2)$$

上式中,  $[b(A), S(A)]$  为关于  $A$  的一个信任区间,  $m(B)$  表示  $B$  的 BPA 值。

(2) 组合法则 设  $b_1, b_2, \dots, b_n$  是同一辨别框  $\theta$  上的信任函数,  $m_1, m_2, \dots, m_n$  是对应的 BPA, 如果  $b_1 \oplus b_2 \oplus \dots \oplus b_n$  存在, 且 BPA 为  $m$ , 则  $\forall A \subseteq \theta, A \neq \emptyset$

$$m(A) = K_n \sum_{A_1 \cap A_2 \cap \dots \cap A_n = A} m_1(A_1) m_2(A_2) \dots m_n(A_n) \quad (3)$$

上式中,  $K_n = 1/N_n$ ,

$$N_n = \sum_{A_1 \cap A_2 \cap \dots \cap A_n \neq \emptyset} m_1(A_1) m_2(A_2) \dots m_n(A_n)$$

### 2.2.2 证据组合的算法实现

由于上述经过交叉训练的 BP 神经网络所获取的知识不亚于该领域专家的知识, 所以再对 BP 神经网络输出的结果归一化, 就可以作为 BPA。设第  $n$  个 BP 神经网络的输出是  $y_{n,i}$ , 其中  $n=1, 2, \dots, N$ ,  $N$  是 BP 神经网络的总个数,  $i=1, 2, \dots, C$ ,  $C$  是水质类别分类种数, 而将  $y_{n,i}$  归一化后得到

$$\hat{y}_{n,i} = \frac{y_{n,i}}{\sum_{i=1}^C y_{n,i}} \quad (4)$$

然后将  $\hat{y}_{n,i}$  作为 BPA 值, 再利用式 (3) 的证据组合规则, 即可得到最终的水质类别评价结果。

## 3 实验与结果分析

目前, 对于湖泊水质的监测及水质状况识别, 多采用空间分辨率较高的陆地卫星 (如 TM 等) 进行研究。本实验分析以太湖为例, 所采用的原始信息包括 Landsat 5 TM 遥感图像数据和同步的地面水质监测数据, 获取时间都是 1997-05-04。地面监测点的分布如图 2 所示, 其中  $\star 1 \sim \star 11$  为地面监测点。

### 3.1 数据的预处理

在实验分析中, 将 TM 图像的灰度值转换为辐射值后作为一幅遥感图像, 而将 TM 图像各波段的主成分分量作为另外一幅遥感图像。由于 D-S 证据




图 2 太湖水质地面监测点分布图 (部分)

Fig. 2 Location of sampling stations of Taihu lake

理论的组合规则要求组合的证据必须是独立的 (虽然 TM 图像的辐射值和主分量具有一定的相关性, 但是经过 BP 神经网络的训练 (非线性映射), 且其得出的相应证据可以近似认为是独立的, 所以用上述模拟的不同遥感图像来验证本方法是可行的。具体实现方法是在对 TM 图像进行大气校正的基础上, 用 TM 图像的第 1 波段、第 2 波段、第 3 波段这 3 个波段的辐射值 (分别记做  $r_1, r_2$  和  $r_3$ ) 和其主成分分量 (第 1、2 和 3 主分量分别记做  $p_1, p_2$  和  $p_3$ ) 分别作为 BP 神经网络 1 的输入和 BP 神经网络 2 的输入。

### (1) TM 图像数据预处理

预处理包括辐射校正、几何校正和大气校正, 其中主要是大气校正。大气校正一般可通过 3 种途径, 即辐射传递方程式计算法、野外波谱测试回归法及多波段图像对比分析法来进行<sup>[7]</sup>。本实验采用多波段图像对比法中的直方图法, 首先将 TM 图像的第 1、第 2、第 3 波段这 3 个波段的灰度值分别减去 17、11 和 8, 然后用遥感图像处理软件 ENVI 3.4 将 TM 图像灰度值转换为辐射值。

### (2) 各个地面监测点的坐标转换

实验利用 MapInfo 7.0 来获取与各地面监测点对应的 TM 图像的坐标。

### (3) 各地面监测点的水质参数的预处理

由于 BP 神经网络的目标矢量是各个地面监测点的水质所属类别, 因此针对各监测点, 需将其具体的水质参数转化为水质类别。本文选择如下几种水质参数: 叶绿素  $\alpha$  (Chl- $\alpha$ )、高锰酸盐指数 (CODMn)、生化需氧量 (BOD5)、总磷 (TP)、总氮

(TN)。对上述5种水质参数,采用平均污染指数法<sup>[8]</sup>求取的某个监测点的综合污染指数如下:

$$P_j = \frac{1}{n} \sum_{i=1}^n p_{i,j} = \frac{1}{n} \sum_{i=1}^n \frac{C_{i,j}}{\hat{C}_{i,j}} \quad (5)$$

其中, $p_{i,j}$ 为j监测点i项污染指标的污染指数, $C_{i,j}$ 为j监测点i项污染指标的年平均浓度值, $\hat{C}(i,j)$ 为j

监测点i项污染指标的评价标准值(一般取Ⅲ类标准), $n$ 为选取污染指标的项数。

根据式(5),先求出各个地面监测点的综合污染指数(以GBZB1-1999的Ⅲ为标准),再对综合污染指数进行划分,其所确定出的各监测点的水质所属类别如表1所示。

表1 地面监测点的水质参数、综合污染指数及水质类别划分  
Tab. 1 Water quality parameter of sampling stations, comprehensive pollution index and water quality classification (单位:mg/L)

| 项目     | 地面监测点 |       |       |       |       |       |       |       |       |       |       |
|--------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
|        | 1     | 2     | 3     | 4     | 5     | 6     | 7     | 8     | 9     | 10    | 11    |
| Chl-α  | 0.039 | 0.022 | 0.016 | 0.017 | 0.013 | 0.016 | 0.017 | 0.008 | 0.047 | 0.016 | 0.022 |
| CODMN  | 10.0  | 4.2   | 5.1   | 3.7   | 3.5   | 2.7   | 2.5   | 2.3   | 5.9   | 4.0   | 5.0   |
| BOD5   | 1.4   | 1.6   | 1.7   | 1.4   | 1.3   | 1.1   | 1.8   | 0.8   | 4.3   | 3.8   | 5.7   |
| TP     | 0.130 | 0.110 | 0.080 | 0.070 | 0.100 | 0.110 | 0.100 | 0.200 | 0.560 | 0.090 | 0.100 |
| TN     | 5.43  | 2.39  | 4.42  | 2.96  | 3.58  | 3.07  | 1.92  | 7.33  | 6.88  | 3.91  | 6.69  |
| 综合污染指数 | 5.76  | 3.10  | 4.12  | 3.04  | 3.60  | 3.37  | 2.57  | 6.74  | 10.37 | 3.94  | 6.11  |
| 水质类别   | Ⅳ     | Ⅱ~Ⅲ   | Ⅳ     | Ⅱ~Ⅲ   | Ⅱ~Ⅲ   | Ⅱ~Ⅲ   | Ⅱ~Ⅲ   | Ⅳ     | Ⅴ     | Ⅱ~Ⅲ   | Ⅳ     |

依据太湖流域的实际情况,综合污染指数与水质类别的量化关系如下:

- ①  $P_j \leq 2.0$ ,以Ⅰ~Ⅱ类水质为主,水质良好;
- ②  $2.0 < P_j \leq 4.0$ 时,以Ⅱ~Ⅲ类水质为主,水质一般;
- ③  $4.0 < P_j \leq 8.0$ 时,以Ⅳ类水质为主,水质较差;
- ④  $8.0 < P_j \leq 12.0$ 时,以Ⅴ类水质为主,水质很差;
- ⑤  $P_j > 12.0$ 时,以劣Ⅴ类水质为主,水质特别差。

(4)水质类别的编码

根据以上分析,确定BP神经网络的希望输出编码为Ⅰ~Ⅱ类水编码为0.1 0.1 0.1 0.1 0.9;Ⅱ~Ⅲ类水编码为0.1 0.1 0.1 0.9 0.1;Ⅳ类水编码为0.1 0.1 0.9 0.1 0.1;Ⅴ类水编码为0.1 0.9 0.1 0.1 0.1;劣Ⅴ类水编码为0.9 0.1 0.1 0.1 0.1。

3.2 实验分析

为了使BP神经网络的训练不致于出现训练饱和现象,需对网络的输入进行归一化处理。在BP神经网络交叉训练过程中,首先,不失一般性使BP神经网络1和BP神经网络2的训练样本和验证样本的划分一致,其次再逐渐调整隐层神经元数目,通过验证样本的验证精度、训练时间和迭代次数的对比来确定BP神经网络1和BP神经网络2的隐层神经元数目,经试验确定的隐层神经元数目都为

10,神经网络的输入、目标及训练集和验证集的划分如表2所示,其中训练集用于对BP神经网络进行训练,而验证集则在对BP神经网络进行训练的同时用于监控网络的训练进程。

验证样本的输出如表3所示。

对表3中的BP神经网络1和BP神经网络2的输出进行归一化处理,先分别得到各类水质的BPA值,然后再将两者的BPA值进行融合,即进行证据组合,其结果如表4所示。

根据表4的证据组合结果,再结合水质类别的编码,就可以很容易看出1、2和11号地面监测点的水质类别判断正确。虽然BP神经网络1和BP神经网络2对1、2和11号监测点的水质判别也是正确的,但是所判断的水质所属类别与其他类别的差距较小(以归一化的输出为参考),例如,以1号地面监测点为例,其BP神经网络1判别属于Ⅳ水质的概率为0.657,而属于Ⅴ类水质的概率为0.217;BP神经网络2判别属于Ⅳ水质的概率为0.701,而属于Ⅴ类水质的概率为0.111;但是通过证据组合得到属于Ⅳ水质的概率为0.932,而属于Ⅴ水质的概率为0.049,可见,通过证据组合以后,属于某一类水质的BPA值与其他类别的BPA值的差距拉大,也即各地面监测点水质类别判断正确的可信度增大了。

表 2 经过交叉训练确定的神经网络输入、目标及样本集的划分

Tab. 2 Partition of input, target and samples set of neural network by crossing-trained

| 项目           |       | 训练样本  |       |       |       |       |       |       |       | 验证样本  |       |       |
|--------------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
|              |       | 3     | 4     | 5     | 6     | 7     | 8     | 9     | 10    | 1     | 2     | 11    |
| BP 神经网络 1 输入 | $r_1$ | 0.677 | 0.645 | 0.807 | 0.774 | 0.807 | 0.807 | 0.129 | 0.774 | 0.516 | 0.774 | 0.742 |
|              | $r_2$ | 0.773 | 0.818 | 0.864 | 0.818 | 0.864 | 0.909 | 0.182 | 0.818 | 0.591 | 0.818 | 0.955 |
|              | $r_3$ | 0.487 | 0.568 | 0.730 | 0.622 | 0.595 | 0.757 | 0.243 | 0.730 | 0.324 | 0.757 | 1.000 |
| BP 神经网络 2 输入 | $p_1$ | 0.663 | 0.682 | 0.844 | 0.778 | 0.796 | 0.863 | 0.141 | 0.817 | 0.475 | 0.827 | 0.921 |
|              | $p_2$ | 0.174 | 0.298 | 0.399 | 0.283 | 0.238 | 0.438 | 0.127 | 0.412 | 0.051 | 0.444 | 0.775 |
|              | $p_3$ | 0.258 | 0.242 | 0.571 | 0.472 | 0.325 | 0.490 | 0.948 | 0.668 | 0.319 | 0.717 | 0.736 |
| 目标           |       | 0.1   | 0.1   | 0.1   | 0.1   | 0.1   | 0.1   | 0.1   | 0.1   | 0.1   | 0.1   | 0.1   |
|              |       | 0.1   | 0.1   | 0.1   | 0.1   | 0.1   | 0.1   | 0.9   | 0.1   | 0.1   | 0.1   | 0.1   |
|              |       | 0.9   | 0.1   | 0.1   | 0.1   | 0.1   | 0.9   | 0.1   | 0.1   | 0.9   | 0.1   | 0.9   |
|              |       | 0.1   | 0.9   | 0.9   | 0.9   | 0.9   | 0.1   | 0.1   | 0.9   | 0.1   | 0.9   | 0.1   |
|              |       | 0.1   | 0.1   | 0.1   | 0.1   | 0.1   | 0.1   | 0.1   | 0.1   | 0.1   | 0.1   | 0.1   |

表 3 BP 神经网络的输出结果

Tab. 3 Output of BP neural network

| 项目           | 监测点 | 输出      |         |         |         |         |  |
|--------------|-----|---------|---------|---------|---------|---------|--|
| BP 神经网络 1 输出 | 1   | 0.112 5 | 0.329 6 | 0.999 0 | 0.000 6 | 0.078 1 |  |
|              | 2   | 0.100 0 | 0.100 0 | 0.091 4 | 0.908 7 | 0.100 0 |  |
|              | 11  | 0.099 9 | 0.100 1 | 0.999 5 | 0.000 5 | 0.100 1 |  |
| BP 神经网络 2 输出 | 1   | 0.083 2 | 0.146 9 | 0.925 6 | 0.041 1 | 0.123 0 |  |
|              | 2   | 0.100 0 | 0.100 0 | 0.193 5 | 0.806 4 | 0.100 0 |  |
|              | 11  | 0.100 2 | 0.100 5 | 0.995 5 | 0.004 5 | 0.100 1 |  |

表 4 BP 神经网络 BPA 值及融合结果

Tab. 4 BPA of BP neural network and the result of fusion

| 项目           | 监测点   | I ~ II | II ~ III | IV    | V     | 劣 V   |
|--------------|-------|--------|----------|-------|-------|-------|
| BP 神经网络 1 输出 | 1     | 0.051  | 0.001    | 0.657 | 0.217 | 0.074 |
|              | 2     | 0.077  | 0.699    | 0.070 | 0.077 | 0.077 |
|              | 11    | 0.077  | 0.000    | 0.769 | 0.077 | 0.077 |
| BP 神经网络 2 输出 | 1     | 0.093  | 0.031    | 0.701 | 0.111 | 0.063 |
|              | 0.077 | 2      | 0.077    | 0.620 | 0.149 | 0.077 |
|              | 0.077 | 11     | 0.077    | 0.004 | 0.765 | 0.077 |
| 融合结果         | 1     | 0.010  | 0.000    | 0.932 | 0.049 | 0.009 |
|              | 2     | 0.013  | 0.939    | 0.023 | 0.013 | 0.013 |
|              | 11    | 0.010  | 0.000    | 0.971 | 0.010 | 0.010 |

3.3 与单一神经网络的比较分析

为了说明本文新方法比采用单一神经网络进行水质状况识别的方法更具有优越性,本文从“邻域参考”和“经验参考”两方面加以比较分析。所谓“邻域参考”就是考虑到某一地面监测点及其邻域的水质应具有相同的类别;所谓“经验参考”就是根据太湖的地理信息知识来识别水质类别(如太湖的西北区,水质多为 V 类或劣 V 类,而南区水质则多为 II ~ III 类)。

(1) 邻域参考

以 3 号地面监测点及其邻域某一点为例来对本文方法与神经网络方法的水质识别效果加以说明。若已知 3 号地面监测点的水质类别为 IV 类,则 3 号监测点周围的小区域的水质也应该为 IV 类水质。在对应的 TM 图像中,选取和 3 号监测点相距 2 个像素的某一点,其对应的经过归一化处理的辐射值  $r_1$ 、 $r_2$  和  $r_3$  分别为 0.677 4、0.727 3 和 0.459 5,经过归一化处理的主分量值  $p_1$ 、 $p_2$  和  $p_3$  分别为 0.616 0、0.265 5 和 0.208 1。在进行水质识别时,先把该点辐射值输入到 BP 神经网络 1,而将主分量值输入到 BP 神经网络 2,然后分别对两个 BP 神经网络的输出进行归一化,得到归一化的输出值分别为[0.085 7 0.096 3 0.987 3 0.011 4 0.105 7]、[0.1 0.1 0.128 4 0.871 6 0.1]。由此判断 BP 神经网络 1、BP 神经网络 2 识别的水质分别为 IV 类、II ~ III 类,到底哪一类更可靠呢? 把两类输出经 D-S 证据组合后的 BPA 值为[0.052 0.058 0.766 0.060 0.064],取与 BPA 值最大值对应的水质类别为识别结果,据其可判定与该点对应的水质类别为 IV 类水质,可见这种判断结果与邻域法的判别是一致的,这表明尽管 BP 神经网络 2 水质识别错误,但经过 D-S 证据推理融合后仍可以给出正确的水质判别。

(2) 经验参考

以太湖西北 TM 图像上的某一点为例来进行说明,与该点对应的经过归一化处理的辐射值  $r_1$ 、 $r_2$  和  $r_3$  分别为 0.258 1、0.091 和 0.135 1,而经过归一化处理的主分量值  $p_1$ 、 $p_2$  和  $p_3$  分别为 0.161 2、0 和 1,然后把该点的辐射值和主分量值分别输入到 BP 神

神经网络1和BP神经网络2,再分别对两个BP神经网络的输出进行归一化,得到的归一化输出分别为[0.103 6 0.897 1 0.000 5 0.965 3 0.1]、[0.175 3 0.999 1 0.000 4 0.022 0.066],根据BP神经网络1的输出可判断该点的水质类别是Ⅱ~Ⅲ类,而根据BP神经网络2的输出则可以判定该点的水质类别是Ⅴ类,两者判定也不一致。由于根据经验法,太湖的西北区是重污染区,所以判定该点的水质类别是Ⅴ类是合理的。根据经证据组合以后的BPA值为[0.019 0.951 0.000 0.023 0.007],可以判定该区水质类别是Ⅴ类,其与经验法的判定是一致的。由此可见,当用BP神经网络1进行水质识别错误时,而经过D-S证据推理融合后,却可以给出正确的水质判别。

由上述分析可见,当两个神经网络对某一点的水质类别判定出现不一致时,证据组合仍可以给出正确的水质判别,这表明系统具有容错性,同时也说明,证据组合判别的水质较单一的神经网络方法更趋于合理。

## 4 结 论

采用基于神经网络-证据理论的遥感图像数据融合处理方法来进行湖泊水质状况识别,比采用单一遥感图像的神经网络方法更具有优越性,因为:(1)可以增加水质识别的容错性,如当某个神经网络水质状况识别有误时,系统的容错功能仍可以使监测系统正常工作,并输出可靠的信息,这对于水质监测来说尤为重要,因为水质监测参数的多样性及监测环境的复杂性,致使监测信息常具有不确定性;(2)融合了多源水质的信息,使水质评价更加可靠。实践表明,尽管受到实验数据的限制,但也能够说明新方法用于湖泊水质类识别和评价是可行的。进一步的研究工作是,获取太湖同一时间的不同遥感图

像(光学遥感图像及SAR图像等),以便研究新方法用于太湖水质识别和评价软件系统的开发。

## 参考文献 (References)

- 1 Louis K E, Yan X H. A neural network model for estimating sea surface chlorophyll and sediments from Thematic Mapper imagery [J]. Remote Sensing of Environment, 1998, 66(2): 153 ~ 165.
- 2 Keiner L E, Brown C W. Estimating oceanic chlorophyll concentrations with neural networks [J]. International Journal of Remote Sensing, 1999, 20(1): 183 ~ 188.
- 3 Lin Z G, Xu L Z, Huang F C. The method of data fusion based on water quality remote sensing image and land monitoring [A]. In: The Chinese Conference 2004 of Electronic & Information Technology Vol. A [C]. Beijing, 2004: 47 ~ 55. [林志贵, 徐立中, 黄凤辰等. 水质遥感图像与地面监测数据融合处理方法 [A]. 见: 中国电子与信息工程学术年会论文集 (2004) A 卷 [C], 北京, 2004: 47 ~ 55.]
- 4 Zhang Y Z, Pulliainen J T, Koponen S S. Water quality retrievals from combined landsat TM data and RES-2 SAR data in the gulf of Finland [J]. IEEE Transactions on Geoscience and Remote Sensing, 2003, 41(3): 622 ~ 629.
- 5 Lin Z G, Xu L Z, Huang F C. Multi-source monitoring data fusion and assessment model on water environment [A]. In: The Third International Conference on Machine Learning and Cybernetics (ICMLC2004) [C]. Shanghai, 2004: 2505 ~ 2510.
- 6 Yan A X, Zhang R S, Liu M C. Large artificial neural networks applied to the prediction of retention indices of acyclic and cyclic alkanes, alkenes, alcohols, esters, ketones, and ethers [J]. Computers and Chemistry, 1998, 22(5): 405 ~ 412.
- 7 Zhang X C, Huang Z C, Zhao Y H. Remote sensing digital image processing [M]. Hangzhou, China: Zhejiang University Press, 2003: 57 ~ 60. [章孝灿, 黄智才, 赵元洪. 遥感数字图像处理 [M]. 杭州: 浙江大学出版社, 2003: 57 ~ 60.]
- 8 Jiang H H, Zhu J P, Liang D H. The relationship between comprehensive pollution index assessment and water quality type distinguishing [J]. Environmental Monitoring in China, 1999, 16(5): 46 ~ 48. [蒋火华, 朱建平, 梁德华等. 综合污染指数评价与水质类别判定的关系 [J]. 中国环境监测, 1999, 16(5): 46 ~ 48.]