



DOI: 10.13476/j.cnki.nsbdkq.2016.02.006

岳佳佳, 庞博, 张艳君, 等. 基于神经网络的宽浅型湖泊水质反演研究[J]. 2016, 14(2): 26-31.

YUE Jia jia, PANG Bo, ZHANG Yan jun, et al. Water quality inversion in wide and shallow lake based on artificial neural network[J]. 2016, 14(2): 26-31. (in Chinese)

基于神经网络的宽浅型湖泊水质反演研究

岳佳佳¹, 庞博¹, 张艳君², 刘佳明²

(1. 北京师范大学水科学研究院, 北京 100875; 2. 武汉大学水资源与水电工程科学国家重点实验室, 武汉 430072)

摘要: 城市浅型湖泊治理是城市生态文明建设的重要组成部分。通过对黄石磁湖的 IKONOS 遥感影像进行预处理, 建立了水质参数与卫星波段的多元线性回归模型、BP 神经网络模型和 RBF 神经网络模型。通过比较不同模型的结果, 运用可靠模型对整个湖体的 COD、NH₃-N、TN、TP 指标进行反演。结果表明, 神经网络模型对于磁湖水质指标的反演结果显著优于多元线性回归模型, 其中 BP 神经网络模型对 NH₃-N、TP 的模拟效果好, RBF 神经网络模型对 COD、TN 的模拟效果较好。

关键词: 磁湖; 遥感; 神经网络; 线性回归; 水质反演

中图分类号: P334 文献标志码: A 文章编号: 1672-1683(2016)02-0026-06

Water quality inversion in wide and shallow lake based on artificial neural network

YUE Jia jia¹, PANG Bo¹, ZHANG Yan jun², LIU Jia ming²

(1. College of Water Sciences, Beijing Normal University, Beijing 100875, China;

2. College of Water Resources and Hydropower, Wuhan University, Wuhan 430072, China)

Abstract: The management of urban shallow lakes plays an important role in the urban ecological civilization construction. Using the IKONOS remote sensing image, two artificial neural network models, based on the BP (Back Propagation) and RBF (Radical Basis Function), were set up to inverse the COD, NH₃-N, TN and TP quality conditions of the Cihu Lake. The proposed models were also compared with the multivariate linear regression model. The results indicated that the model efficiency of the two ANN models were significantly higher than the multiple linear regression model. The BP model fitted the observed data better in the simulation of the NH₃-N, TP, while the RBF neural network showed advantages in the simulation of the COD and TN.

Key words: Cihu Lake; remote sensing; artificial neural network; linear regression; water quality inversion

城市浅型湖泊是城市生态环境系统的重要组成部分, 但是因其具有水浅、流动性差, 底泥污染严重等特点, 水环境问题较为突出^[1]; 同时随着经济的迅速发展, 湖泊水质的污染日趋严重, 因此, 对城市浅型湖泊的治理已经成为我国很多城市生态文明建设面临的迫切问题。

磁湖位于湖北省黄石市中心, 径流面积 62.8 km², 湖泊面积 8.2 km², 平均水深 1.75 m, 湖体容量 17.48 万 m³^[2], 是一个以城市景观和生态调节为主要功能的湖泊^[3]。对磁湖的治理近年来一直在进行, 但水质并未得到很好的恢复。要从根本上改善和治理水体环境, 就要对水体水质指标进行监测, 对

收稿日期: 2015-03-14 修回日期: 2015-08-26 网络出版时间: 2016-04-14
网络出版地址: <http://www.cnki.net/kcms/detail/13.1334.TV.20160414.1447.015.html>

基金项目: 国家自然科学基金青年科学基金资助项目(51309009; 51209162)

Fund: National Natural Science Foundation of China(51309009; 51209162)

作者简介: 岳佳佳(1991-), 女, 甘肃酒泉人, 主要从事水文水资源方面的研究。E-mail: jiajiayue@mail.bnu.edu.cn.

通讯作者: 庞博(1979-), 男, 河南潢川人, 副教授, 主要从事水文水资源方面的研究。E-mail: pb@bnu.edu.cn.

湖水水质年内变化状况有准确的把握,依据水质参数的差异进行专项治理。

常用的水质监测手段主要包括人工采样分析和自动检测,这两种方法会消耗大量人力、物力,且获得的数据在时间和空间上都不连续,难以达到大范围、实时性的水质监测要求。而水质遥感技术由于具有快速、连续、动态、范围广、相对成本低等优点,在水质监测中的应用日益受到重视^[4-5]。

水质遥感反演是一个非线性过程,影响因素较多。针对不同地域、不同特点的水质参数反演寻求合适的反演模型是水质遥感的研究难点。人工神经网络以其自学习、较好的容错性和优良的非线性逼近能力,在水质遥感反演领域得到研究者的重视^[6-8],目前 BP 神经网络、RBF 神经网络等已广泛应用于水质预测,但大部分用于渭河、鄱阳湖等大流域的研究,神经网络方法是否适用于城市浅型湖泊需要进一步研究^[6]。

本文以黄石磁湖为研究对象,利用 IKONOS 卫星的高分辨率遥感图像和水质参数实测数据,建立 BP 神经网络反演模型和 RBF 神经网络反演模型,通过与多元线性回归模型结果对比,探究神经网络在磁湖水质反演中的可行性,以及 BP 神经网络和 RBF 神经网络在磁湖水质反演中的优劣,为整个磁湖水质进行遥感反演提供一种更高效快速的方法。

1 数据采集和处理

1.1 数据收集

2012 年 4 月至 2013 年 3 月在湖北磁湖选取了 9 个采样点进行了为期一年的水质监测,采样点位置见图 1。选取的水质监测指标为 COD(化学需氧量)、NH₃-N(氨氮)、TP(总磷)、TN(总氮)。




图 1 磁湖采样点分布

Fig. 1 Sampling sites in Cihu Lake

遥感数据来自高分辨率 IKONOS 卫星图像,时相为 2012 年 11 月 14 日,包含 1m 全色(黑白)分辨率图像和 4m 多谱段(彩色)分辨率图像。

1.2 数据处理

1.2.1 辐射定标

辐射定标是将传感器记录的电压或数字量化值(DN)转换成绝对辐射量度值(辐射率)的过程,是消除非地物变化所造成的图像辐射值改变的有效方法。将 IKONOS 影像中记录的遥感影像灰度值(DN)以及定标参数(Offset 和 Gain)根据如下线性关系,得到辐射亮度值 L :

$$L = \text{Gain} * \text{DN} + \text{Offset} \quad (1)$$

式中: L 为辐射亮度值, $W/(cm^2 \cdot \mu m \cdot sr)$ 。

1.2.2 大气校正

遥感所利用的各种辐射能均要与地球大气层发生相互作用,或散射、或吸收,而使能量衰减,并使光谱分布发生变化。大气的衰减作用对不同波长的光是有选择性的,因而图像中不同地区不同地物的像元灰度值所受大气影响程度不同。大气校正的目的正是消除这些影响,获得地物反射率的真实物理模型参数。本文在 ENVI4.8 运行环境下,利用 FLAASH 大气校正模块对图像进行处理,基于太阳波谱范围内(不包括热辐射)和平面朗伯体(或近似平面朗伯体),在传感器处接受的像元光谱辐射亮度公式为

$$L = \left[\frac{A * \rho}{1 - \rho_r * S} \right] + \left[\frac{B * \rho}{1 - \rho_r * S} \right] + (L_a) \quad (2)$$

式中: L 为传感器处像元接收到的总辐射亮度; ρ 为像素表面反射率; ρ_r 为像素周围平均表面反射率; S 为大气球面反照率; L_a 为大气后向散射反射率(大气程辐射); A 、 B 为取决于大气条件和几何条件的两个系数。

2 相关性分析

水体的光谱特征是由其中的各种物质对光辐射的吸收和散射性质决定的^[9],当水体受到污染时,其光谱特征发生变化,所以遥感图像各波段与水质参数间存在一定的相关性。表 1 分别计算了各水质参数之间的相关性以及各个波段之间的相关性。水质参数间的相关性较好时,较少或相似的波段组合即可模拟四种水质参数的相关关系。而计算各波段之间的相关性,可在设计不同的波段组合时提供参考,避免高相关性的波段的重复计算,减少计算量。

表 2 为各波段与各水质参数的相关关系。由表可知,Blue、Green、Red、NIR 波段分别与 TP、TP、COD 和 TN 的相关性较好。相比较而言,与 TP 的相关性最好的是 Green 波段, NH₃-N 与 Green 波段的相关性也最好。

表 1 波段与水质参数的相关性矩阵

Tab. 1 Correlation matrix of the band and the water quality parameter

| | COD | NH ₅ -N | TN | TP |
|--------------------|--------|--------------------|-------|-----|
| COD | 1 | | | |
| NH ₅ -N | -0.693 | 1 | | |
| TN | -0.792 | 0.958 | 1 | |
| TP | -0.478 | 0.803 | 0.828 | 1 |
| | Blue | Green | Red | NIR |
| Blue | 1 | | | |
| Green | 0.806 | 1 | | |
| Red | 0.519 | 0.826 | 1 | |
| NIR | 0.697 | 0.893 | 0.652 | 1 |

表 2 各波段反射率和相应水质参数相关性

Tab. 2 Correlation of the band reflectance and the corresponding water quality parameters / (mg · L⁻¹)

| | | COD | NH ₃ -N | TN | TP |
|-------|-------------|--------|--------------------|--------|--------|
| Blue | Pearson 相关性 | 0.198 | -0.556 | -0.553 | -0.690 |
| | 显著性(双侧) | 0.610 | 0.120 | 0.122 | 0.040 |
| Green | Pearson 相关性 | 0.355 | -0.583 | -0.635 | -0.785 |
| | 显著性(双侧) | 0.349 | 0.100 | 0.066 | 0.012 |
| Red | Pearson 相关性 | -0.080 | -0.239 | -0.229 | -0.482 |
| | 显著性(双侧) | 0.839 | 0.536 | 0.553 | 0.189 |
| NIR | Pearson 相关性 | 0.477 | -0.550 | -0.686 | -0.673 |
| | 显著性(双侧) | 0.194 | 0.125 | 0.041 | 0.047 |

3 水质参数反演模型

3.1 多元线性回归模型

利用 IKONOS 遥感数据的 4 个波段以及表 1 的计算结果,建立了 42 种不同的波段组合方式。通过分析各项水质参数与各种波段组合间的相关关系,建立多元线性回归方程。比较发现,利用自变量逐步筛选法获得的结果较好,当变量的回归系数的显著性水平 < 1.0 时则进入方程,当变量的回归系数的显著性水平 > 2.0 时从方程中删去该变量,在此显著性水平的约束下,确定了在各项水质参数与各波段组合的相关性。表 3 为多元线性回归模型计算结果,其中 B1、B2、B3 和 B4 分别对应 Blue、Green、Red、NIR 波段。

表 3 线性回归模型计算结果

Tab. 3 Calculation results of the linear regression model

| 水质参数 | 显著相关波段 | 相关波段系数 | 常数项 | R |
|--------------------|--------|----------|---------|-------|
| COD | B4/B3 | 63.767 | -20.108 | 0.687 |
| NH ₅ -N | B2* B4 | -37.880 | 1.769 | 0.732 |
| TN | B1* B4 | -108.587 | 3.823 | 0.851 |
| TP | B22 | -140.673 | -4.659 | 0.992 |
| | B2 | 51.919 | | |

此结果与表 1、表 2 计算所得结果相同。

3.2 BP 神经网络模型

人工神经网络由于具备自适应、自组织和容错性,适合模拟较为复杂的关系。理论上已经证明:具有偏差和至少一个 S 型隐含层加上一个线性输出层的网络,能够逼近任何有理数^[11]。基本 BP 算法包括两个方面:信号的前向传播和误差的反向传播。即计算实际输出时按从输入到输出的方向进行,而权值和阈值的修正从输出到输入的方向进行。本文采用 BP 神经网络,将 IKONOS 影像的 4 个波段数据作为输入,相应的水质参数作为期望输出。为了加快神经网络的收敛速度,使网络具有更好拟合效果,在模型建立之前,需对样本进行归一化处理,使得输入、目标值在 (-1, 1) 之间。学习速率决定每一次循环中所产生的权值变化量,小的学习速率能保证网络的误差值不跳出误差表面的低谷而最终趋于最小误差值。所以在本次模拟中,设定学习速率为 0.01,以保证系统的稳定性。

在训练过程中,逐步调整隐含层和神经元的个数,通过对训练结果的误差比较及计算效率的分析,最终确定在 4 个隐含层,4 个神经元的结构时,模型能较快且较好的模拟,所以网络的结构为 4-4-1。在 Matlab 中通过调用神经网络工具箱中 newff() 函数训练网络,隐含层神经元采用的是 S 型函数“tansig”,输出层采用的是线性函数“purelin”,训练函数采用的是“trainlm”,设定训练步数为 2000,针对不同的水质参数,选取不同的训练目标,对网络进行训练。训练目标的取值为不同水质参数的实测数据中位数的 1/100。

表 4 BP 神经网络模型参数

Tab. 4 BP neural network model parameters

| 水质参数 | 训练目标 | 训练步长 | 实际步长 | R |
|--------------------|--------|-------|------|-------|
| COD | 0.285 | 2 000 | 278 | 0.974 |
| NH ₅ -N | 0.015 | 2 000 | 38 | 0.999 |
| TN | 0.028 | 2 000 | 27 | 0.949 |
| TP | 0.0025 | 2 000 | 19 | 0.977 |

3.3 RBF 神经网络模型

基于 RBF 神经网络具有训练速度快、能收敛到全局最优点、可最佳逼近等优点,本文使用 RBF 神经网络建立水质反演模型,验证其对磁湖水质反演的适用性。

RBF 网络是一个三层的网络,除了输入输出层之外仅有一个隐层。隐层中的转换函数是局部响应的高斯函数,而其他前向型网络,转换函数一般都是全局响应函数。RBF 的训练时间较短。它对函数

的逼近是最优的, 隐层中的神经元越多, 逼近越精确。当学习开始之后, 网络会从 0 个神经元开始训练, 通过检查输出误差使网络自动增加神经元, 每次循环使用, 重复过程直到误差达到要求。

径向基网络中常用的径向基函数是高斯函数, 因此径向基神经网络的激活函数表示为:

$$R(x_p - c_i) = \exp\left[-\frac{1}{2\sigma^2} \|x_p - c_i\|^2\right] \quad (3)$$

式中: $\|x_p - c_i\|$ 为欧式范数; c 为高斯函数的中心; σ 为高斯函数的方差。

网络的输出为

$$y_i = \sum_{j=1}^k w_{ij} \exp\left[-\frac{1}{2\sigma^2} \|x_p - c_i\|^2\right] \quad j = 1, 2, \dots, n \quad (4)$$

式中: $x_p = (x_p^1, x_p^2, \dots, x_p^m)^T$ 为第 p 个输入样本, $p = 1, 2, \dots, P$, P 表示样本总数; c_i 为网络隐含层节点的中心; w_{ij} 为隐含层到输出层的连接权值, $i = 1,$

$2, \dots, h$, h 为隐含层的节点数; y_i 为与输入样本对应的网络的第 j 个输出节点的实际输出。

本次建模过程中, 仍然将 IKONOS 影像的 4 个波段数据作为输入数据, 相应的水质参数作为输出数据。在 Matlab 中通过调用神经网络工具箱中 newrb() 来训练网络, 确定各个参数。隐含层神经元激励函数是 radbas, 输出层神经元激励函数为纯线性函数 purline, 模型误差训练目标保持与 BP 神经网络相同。结果发现, 当神经元个数为 6 个时, 模型达到误差目标。

4 结果及分析

4.1 模拟结果比较

本文通过比较三种模型计算结果, 优选最适合磁湖水水质反演的模型。三种方法对各水质参数的模拟结果见图 2, 模拟结果相对误差见表 5- 表 8。

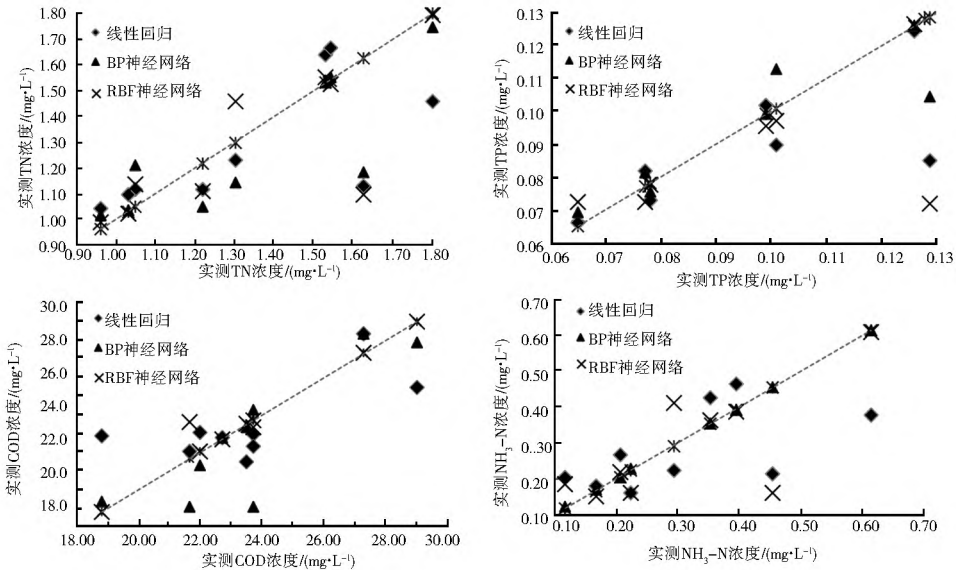


图 2 不同模型模拟结果比较

Fig. 2 The simulation results of different models

表 5 三种方法对 COD 模拟结果相对误差比较

Tab. 5 COD simulation results relative error of three models (%)

| 模拟方法 | 线性回归模型 | BP 神经网络 | RBF 神经网络 |
|---------|--------|---------|----------|
| 模型率定期误差 | 7.841 | 2.408 | 0.000 |
| 模型验证期误差 | 3.945 | 15.908 | 5.216 |
| 平均误差 | 6.975 | 5.408 | 1.159 |
| R | 0.687 | 0.974 | 0.999 |

表 7 三种方法对 TN 模拟结果相对误差比较

Tab. 7 TN simulation results relative error of three models (%)

| 模拟方法 | 线性回归模型 | BP 神经网络 | RBF 神经网络 |
|---------|--------|---------|----------|
| 模型率定期误差 | 9.137 | 5.626 | 3.439 |
| 模型验证期误差 | 17.979 | 19.583 | 22.167 |
| 平均误差 | 11.102 | 8.727 | 7.600 |
| R | 0.851 | 0.949 | 0.982 |

表 6 三种方法对 NH₃-N 模拟结果相对误差比较

Tab. 6 NH₃-N simulation results relative error of three models (%)

| 模拟方法 | 线性回归模型 | BP 神经网络 | RBF 神经网络 |
|---------|--------|---------|----------|
| 模型率定期误差 | 30.787 | 2.684 | 15.135 |
| 模型验证期误差 | 37.782 | 39.099 | 52.700 |
| 平均误差 | 32.341 | 10.776 | 23.483 |
| R | 0.732 | 0.999 | 0.974 |

表 8 三种方法对 TP 模拟结果相对误差比较

Tab. 8 TP simulation results relative error of three models (%)

| 模拟方法 | 线性回归模型 | BP 神经网络 | RBF 神经网络 |
|---------|--------|---------|----------|
| 模型率定期误差 | 3.240 | 4.303 | 4.554 |
| 模型验证期误差 | 22.573 | 15.408 | 24.057 |
| 平均误差 | 7.537 | 6.771 | 8.888 |
| R | 0.992 | 0.977 | 0.982 |

由图 2 可看出, 线性回归模型结果在直线两旁分布相对均匀, 神经网络模拟结果大部分点据比较靠近直线, 而神经网络的率定期误差较小, 验证期误差较大, 因此导致模拟点分布不均。

由表 5- 表 7 看出, 对 COD 参数的模拟三种模型平均误差均小于 10%, 其中 RBF 神经网络模拟效果最好, 在率定期误差接近于 0, 平均误差也仅为 1.159%。NH₃-N 建立的三种模型误差均较大, 其中线性回归模型误差最大, 达到 32.34%, 仅有 BP 神经网络的平均误差小于 20%, 在允许范围内。对于 TN 的模拟, 虽然 RBF 神经网络在验证期误差略大于 20%, 但该模型结果的平均误差最小, 为 7.6%。对于 COD、NH₃-N、TN 三项水质参数, 两种神经网络模型的相关性系数均在 0.9 以上, 显著优于线性回归模型的结果。

由表 8 可以看出, TP 的线性回归模拟效果优于 RBF 神经网络, 但劣于 BP 神经网络。这是因为 TP 与四个波段的相关性均较好(表 2), 线性回归模型的相关系数算法可改进程度较小, 所以三种模型的误差较小, 模拟结果相关性高。考虑到神经网络模型的空间分辨率较高, 最终选择神经网络模型中平均误差较小的 BP 神经网络作为反演模型。

由图 2 及表 5- 表 8 的结果可得, 对于四项水质参数, 神经网络模型的模拟结果显著优于多元线性回归模型, 其中, RBF 神经网络对 COD、TN 的反演效果较好, BP 神经网络对 NH₃-N、TP 的反演效果较好。

4.2 水质遥感反演结果

依据计算结果, 选用 BP 神经网络模型反演整个湖体的 NH₃-N、TP 水质参数; 选用 RBF 神经网络反演整个湖体的 COD、TN 水质参数。将计算结果在 Arcgis 软件中通过低通滤波对像元点的反演结果进行平滑处理, 结果见图 3- 图 6。

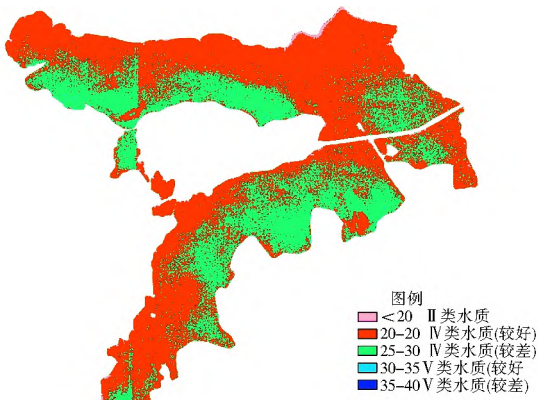


图 3 COD 浓度反演结果

Fig. 3 COD concentration inversion results of different models




图 4 NH₃-N 浓度反演结果

Fig. 4 NH₃-N concentration inversion results of different models




图 5 TN 浓度反演结果

Fig. 5 TN concentration inversion results of different models

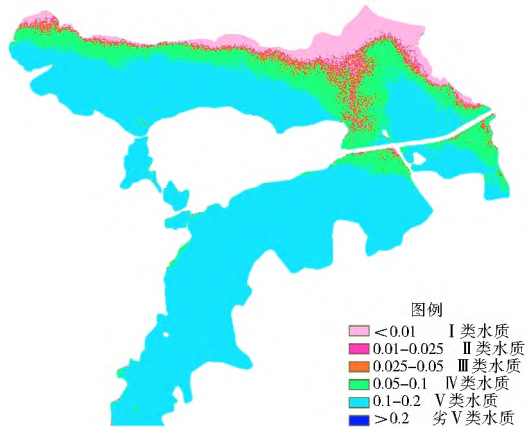


图 6 TP 浓度反演结果

Fig. 6 TP concentration inversion results of different models

反演结果显示, 黄石磁湖的水质状况较差, 总体水质远达不到《湖北省水功能区划》所规定的的Ⅰ类水质标准, 其中, 整个湖体 COD 含量基本达到Ⅰ类水平, 说明该湖泊受到一定程度的有机物污染; NH₃-N 指标大部分保持在Ⅰ类水质, 在湖体南部的左岸部分区域含量达到Ⅰ类水平; 全湖的 TN 含量有较明显的分级, 水质从岸边向湖中心逐渐变好, 说明周围人类活动对湖泊水质有较大影响; 整个湖体

大部分水域 TP 含量达到Ⅲ类水平,在湖的北部近岸区域含量达到Ⅱ类水平,说明湖泊的主要污染物为磷,这是因为当气温降低时,微生物活性降低,底泥在厌氧条件下释放磷,导致水体磷含量较高。(湖泊东北部是磁湖公园,因受到人为影响较大,水质指标不纳入本次研究范围)。

5 结论

本文基于 IKONOS 遥感数据对磁湖湖体水质参数建立了多元线性回归模型、BP 神经网络模型及 RBF 神经网络模型。模拟结果表明水质参数与光波波段之间并不完全是线性相关。线性回归模型因其模拟水质参数与光波波段之间的线性关系,算法比较单一,所以计算得到的相关系数并不高,在 0.6~0.9 左右;而神经网络模仿神经元进行了较为复杂的运算,所以计算得到的相关系数均达到 0.9 以上,神经网络模型的准确性更高。而 BP 神经网络模型和 RBF 神经网络模型对于不同的水质参数模拟结果不同,选用较优模型进行水质反演,对于磁湖的这类城市浅型湖泊的专项治理有很重要的意义。

遥感反演获得的湖体水质指标范围更广,避免了水质监测只能确定采样点的水质的缺点,且遥感图像快速易得,处理方法简单,是一种非常有效的水质监测手段。但在水质反演中,对图像进行的大气校正处理采用的是模块化处理,要开展精确的大气校正方法,使水质反演结果更加准确。

参考文献(References):

- [1] 华祖林,顾莉,刘晓东.调水对改善浅水型湖泊水体的置换率研究[J].水资源保护,2009(1):9-13,17.(HUA Zulin, GU Li, LIU Xiaodong. Improving water exchange rate of shallow lakes through water diversion works[J]. Water Resources Protection, 2009(1):9-13, 17. (in Chinese))
- [2] 张丽莉,赵旭德,胡亨魁,等.磁湖污染现状调查与分析[J].环境保护科学,2008,34(1):17-19.(ZHANG Lili, ZHAO Xude, HU Xiangkui, et al. Investigation and analysis on the Cihu Lake pollution[J]. Environmental Protection Science, 2008, 34(1):17-19. (in Chinese))
- [3] 肖文胜,秦永宏,盖希光,等.引江入湖修复城市内湖生态环境—以磁湖为例[J].环境科学与技术,2009(32):12-17.(XIAO Wensheng, QIN Yonghong, GAI Xiguang, et al. A proposal of diverting water from Yangtze River into Cihu Lake for rehabilitation[J]. Environmental Science & Technology, 2009(32):12-17. (in Chinese))
- [4] Giardino C, Pepe M. Detecting Chlorophyll, Secchi Disk Depth and Surface Temperature in a Subalpine Lake Using Landsat Imagery[J]. The Science of the Total Environment. 2001. 268: 19-29.
- [5] 车夫喜,杨校礼,董壮,等.基于数值模拟的磁湖水质改善效果预测研究[J].人民长江,2014,45(16):12-14.(CHE Fuxi, YANG Jiaoli, DONG Zhuang, et al. Research on water quality improvement prediction of Cihu Lake based on numerical simulation[J]. Yangtze River, 2014, 45(16):12-14. (in Chinese))
- [6] 顾亮,张玉超,钱新,等.太湖水域叶绿素a浓度的遥感反演研究[J].环境科学与管理,2007,32(6):25-29.(GU Liang, ZHANG Yuchao, QIAN Xin, et al. Study on retrieval of chlorophyll a concentration by remote sensing in Taihu Lake[J]. Environment Science and Management, 2007, 32(6):25-29. (in Chinese))
- [7] 余楚,吕敦玉.利用BP神经网络模型进行分类径流模拟[J].南水北调与水利科技,2014,(12)5:109-112.(YU Chu, LY Dunyu. Application of BP neural network in classified runoff simulation[J]. South to North Water Transfers and Water Science & Technology, 2014, (12)5:109-112. (in Chinese))
- [8] Dall'Omo G, Gitelson A, Rundquist DC, et al. Assessing the Potential of SeaWiFS and MODIS for Estimating Chlorophyll Concentration in Turbid Productive Waters Using Red and Near Infrared Bands[J]. Remote Sensing of Environment, 2005. 96: 176-187.
- [9] 李素菊,王学军.内陆水体水质参数光谱特征与定量遥感[J].地理学与国土研究,2002(5):26-30.(LI Sujun, WANG Xuejun. The spectral features analysis and quantitative remote sensing advances of inland water quality parameters[J]. Geography and Territorial Research, 2002(5):26-30. (in Chinese))
- [10] 王建平,程声通,贾海峰,等.用TM影像进行湖泊水色反演研究的人工神经网络模型[J].环境科学,2003,24(2):73-76.(WANG Jianping, CHENG Shengtong, JIA Haifeng, et al. An artificial neural network model for lake color inversion using TM imagery[J]. Environmental Science, 2003, 24(2):73-76. (in Chinese))
- [11] 赵玉芹,汪西莉,蒋赛.渭河水水质遥感反演的人工神经网络模型研究[J].遥感技术与应用,2009,24(1):63-66.(ZHAO Yuqin, WANG Xili, JIANG Sai. Study on neural network model for Weihe River Water quality retrieving using remote sensing image[J]. Remote Sensing Technology and Application, 2009, 24(1):63-66. (in Chinese))
- [12] 王皓,赵冬至,王林,等.水质遥感研究进展[J].海洋环境科学,2012,31(2):285-288.(WANG Hao, ZHAO Dongzhi, WANG Lin, et al. Advance in remote sensing of water quality[J]. Marine Environmental Science, 2012, 31(2):285-288. (in Chinese))
- [13] Semih Ekercin. Water Quality Retrievals from High Resolution Ikonos Multispectral Imagery: A Case Study in Istanbul, Turkey[J]. Water Air Soil Pollut 2007, 183: 239 - 251.
- [14] Jain, S. K. Development of integrated sediment rating curves using ANNs[J]. Journal of hydraulic engineering, 2001, 127(1):30-37.
- [15] Huang W, Foo. Neural network modeling of salinity variation in Apalachicola River[J]. Water research, 2002, 36(1):356-362
- [16] Sharad Kumar Jain. Development of Integrated Sediment Rating Curves Using ANNs[J]. Journal of Hydraulic Engineering, 2001, 127(1):30-37.
- [17] Vladan Babovic. Neural Network Routing for Error Updating of Numerical Models[J]. Journal of Hydraulic Engineering, 2001, 127(3):18F-193.