

基于 BP 神经网络模型的太湖悬浮物浓度遥感定量提取研究

吕 恒¹ 李新国^{1,2} 曹 凯³

(1 中国科学院南京地理与湖泊研究所, 南京市北京东路 73 号, 210008)

(2 中国科学院研究生院, 北京市玉泉路甲 19 号, 100039)

(3 南京大学城市与资源学系, 南京市汉口路 22 号, 210008)

摘 要: 构建了一个含有一个隐含层的两层 BP 神经网络反演模型, 以 TM 数据的前 4 个波段的反射率作为输入, 以悬浮物浓度值作为输出, 成功反演了太湖水体的悬浮物浓度。

关键词: BP 神经网络模型; 悬浮物浓度; 太湖; 定量反演

中图分类号: P237.9

二类水体水质参数的定量提取一直是国际遥感界的研究热点问题之一^[1-8]。由于二类水体光学特征复杂, 成功应用于一类水体的线性反演模型并不能成功应用于二类水体, 二类水体的光谱特征与组分浓度之间的关系并不能用简单的线性关系来表示^[9]。从本质上说, 水质参数的定量提取是一个参数估计的问题。

BP 神经网络模型具备自适应、自组织性, 容错性能非常适合模拟各种错综复杂的关系。Hornik 证明^[10], 具有偏差和至少一个 S 型隐含层加上一线性输出层的网络, 能够逼近任何有理函数。文献[11]认为, 去除大气影响后, 遥感数据直接与水体组分及其浓度有关。因此本文利用 BP 神经网络模型逼近复杂的反函数, 从而利用 TM 数据反演出二类水体太湖的悬浮物浓度。

1 研究方法

1.1 研究区域数据采样

太湖是我国 5 大淡水湖之一, 位于北纬 30°55'40"~31°32'58", 东经 119°52'32"~120°36'10", 实际水面积 2 338.1 km²。水体呈中度富营养化到富营养化, 水质属于 II 类^[12], 是典型的二类水体。

根据卫星过境时间和天气情况在太湖进行准实时采样, 每个采样点进行表层水采样, 同时在实

验室测定悬浮物浓度, 测定方法采用 GB 11901-89 烘干称重法。表 1 是卫星过境时间和采样时间。卫星过境和采样当天天气晴好, 根据气象观测记录, 2002 年 7 月 14 日和 2003 年 1 月 20 日天气晴好, 无云, 无大风, 对水质参数变化影响较小。

表 1 数据采样表

Tab. 1 Table of Sampling Time

卫星过境时间	采样时间	采样点数	数据源
02/7/13	02/7/15	10(后剔除 2 个点)	ETM
03/1/21	03/1/19	12	ETM
03/11/13	03/11/13	21	TM
03/12/15	03/12/15	10(后剔除 2 个点)	TM

1.2 TM 数据预处理

1.2.1 TM 数据精纠正

本次精纠正总误差控制在 0.5 个像元之内, 图像重采样采用最近邻近点法, 这样可以避免光谱信息的丢失; 选择 UTM 投影, WGS84 椭球体, 这样可以使采样点 GPS 定位坐标和遥感图像投影坐标精确匹配。

1.2.2 TM 数据大气校正

本文采用 6S 模型进行大气校正^[13]。在进行大气校正时需要输入以下主要参数。

1) 太阳天顶角、卫星天顶角、太阳方位角、卫星方位角, 也可以输入卫星轨道与时间参数来替代。

2) 大气组分参数, 包括水汽、灰尘颗粒度等参数。本次因缺乏大气实测数据, 选用标准大气模型——中纬度冬天和中纬度夏天。

3) 气溶胶组分参数, 包括水分含量以及烟尘、灰尘等在空气中的百分比等参数。若缺乏精确的实况数据, 可以选用 6S 提供的标准模型来替代。本次选用“大陆模型”来描述大气的气溶胶组分, 气溶胶的大气路径长度, 本次用能见度参数表示。

4) 观测目标的海拔高度及传感器高度。

5) 光谱条件, 可以直接输入光谱波段范围, 也可以将遥感器波段作为输入条件。

6) 其他参数, 若是基于朗伯体大气校正, 直接输入像元的光谱值得到经过朗伯体大气校正后的地面反射率。本次校正基于朗伯体大气校正。

文献[11]认为, 去除大气影响后, 遥感数据直接与水体组分及其浓度相关, 因此, 大气校正模型的好坏, 可以用遥感数据与水体组分的浓度的相关系数表征。图 1 是大气校正前和校正后的 TM 数据 4 个波段与悬浮物浓度的相关系数, 可以看出, 经 6S 模型大气校正后, TM 的 4 个波段与悬浮物浓度的相关性都得到了显著的提高。




图 1 大气校正前后悬浮物浓度与 TM 数据的相关系数

Fig. 1 Correlation of SSC and TM Data Before and After 6S Correction

1.2.3 TM 数据的平滑降噪处理

由于 TM 图像信噪比较低, 图像包含有噪声信息。为了减弱、消除噪声的影响, 取采样点附近相邻像元点的平均值替代该点的反射率值, 以达到平滑图像、消除噪声的目的。本次计算了采样点邻近的 3×3、5×5、7×7、9×9 像元平均反射率, 取所有采样点的平均值。在取邻近像元点平均值时, 在 5×5 阵列已达到一个相对稳定的值, 像元阵列继续增大, 反射率的平均值不再呈显著变化。因此, 取采样点相邻 5×5 的像元的平均值作为该采样点的反射率。

1.2.4 采样数据的 GRU BBS 检验

为了克服少数异常值带来的干扰, 有必要在

建模和统计分析之间检验并剔除样本中的异常值, 本次研究采用 GRU BBS 检验方法。检验的步骤是, 将所有数据从小到大排列, 以两端极值作为可疑值, 然后分别加以检验, 如果发现最大值或最小值是异常, 那么可以将其剔除并进一步检验次大值或次小值, 直到剩余数据的最大值和最小值都不再是异常值为止。利用这一方法共剔除了 4 个采样点的数据。

1.3 BP 神经网络模型拓扑结构的设计

本次参数反演使用仅含有一个隐含层的两层神经网络结构, 网络具有 4 个输入神经元和 1 个输出神经元。神经元的激活函数使用双曲正切 S 型函数。神经网络训练方法采用 Levenberg-Marquardt 算法^[14]。

1) 确定 BP 神经网络初始权重。本文网络权重在[-0.5, 0.5]区域随机生成。

2) 确定网络学习速率。BP 算法的收敛特性和收敛速度很大程度上取决于学习速率 η 这里使用动量法来调整学习速率。所谓的动量法, 是在每个权重调整量上加上一项正比于前一次权重调节量的值:

$$\Delta w(t+1) = \eta \frac{\partial E}{\partial w} + m \Delta w(t) \quad (1)$$

式中, m 为动量系数, 通常 0 < m < 0.9。

动量项起到缓冲与平滑的作用, 有利于改善网络收敛过程中的稳定性, 调节网络的收敛速度。

3) 确定 BP 神经网络的隐含层神经元节点数。隐含层神经元节点数的选择是人工神经网络设计中最为关键的步骤, 它直接影响网络对复杂问题的映射能力。目前隐含层神经元节点数的确定方法都没有严密的理论依据, 只是根据各自的实验结果而得出的结论, 带有很大的特例性, 在很多情况下, 这些方法是无效的。由于应用对象和网络结构的不同, 隐含层的神经元节点数很难用统一的模式确定。本次神经网络模型隐含层节点数的确定方法为: 开始使用很少的隐含层神经元数, 然后进行网络训练和测试, 不断增加隐含层神经元节点数, 比较不同方案训练下的测试结果, 测试结果以计算样本实测值和模拟值的误差均方根 R_{RMSE} 和 PEARSON 相关系数的平方 (R^2) 表示, 具体计算式为:

$$R_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (R_{meas} - R_{mod})^2} \quad (2)$$

式中, R_{meas} 为实测值; R_{mod} 为预测值。

分别计算隐含层神经元数从 2~ 10 的测试样本的神经网络输出值与实测值的 R^2 和 R_{RMSE} 值。

如表 2 所示。

表 2 隐含层不同节点数的 R^2 和 R_{RMSE} 值
Tab. 2 R^2 and R_{RMSE} Value of Different Hide Nodes

隐含层节点数	R^2	R_{RMSE}
2	0.82	9.13
3	0.85	8.68
4	0.96	4.25
5	0.9	7.79
6	0.85	8.33
7	0.96	4.56
8	0.88	7.64
9	0.86	8.14
10	0.84	9.58

从表 2 中可以看出, 隐含层有 4 个节点时, 测试样本网络的输出效果最好, R^2 最大, R_{RMSE} 值最小, 因此, 选用隐含层有 4 个节点的神经网络模型预测太湖的悬浮物浓度。

4) BP 神经网络训练策略的选择。

在对神经网络进行训练时, 要避免过度训练或过度吻合。避免过度训练, 保留一部分样本数据作为测试样本, 而不参加训练, 在训练过程中, 每经过一定的训练次数就停下来, 以检验此时网络对测试样本的测试误差。当发现测试误差开始上升时, 就有可能发生过度训练, 这时并不立即停止训练, 仍继续训练下去, 同时不断地用测试样本对网络进行检验。经过多次比较, 最终确定最佳训练次数。图 2 是训练停止策略示意图。




图 2 训练停止示意图

Fig. 2 Sketch Map of Training Stop Tactic

2 结果分析

在 49 个采样点数据中, 取出 16 个(按照悬浮物浓度从高到低排列, 每隔 2 个样本取一个样本数据)作为模型测试数据, 剩下的 33 个采样点作为训练模型的样本数据。为了和其他模型进行比较, 在 SAS 软件的支撑下还建立了太湖水体悬浮物浓度的线性反演模型, 与建立神经网络模型一样, 一组 33 个样本用于建立模型, 一组 16 个样本用于检验模型, 两个模型所用的两组样本数据完

全一样。

$$\ln SS = -16.635 * TM^2 + 33.626(TM3 - TM1) + 3.34$$

$$R^2 = 0.87, R_{RMSE} = 1.34, F = 97.77,$$

$$P_r > F < 0.0001 \quad (3)$$

式中, R^2 为决定系数; R_{RMSE} 为误差均方根; F 为假设检验 F 统计量; $P_r > F$ 为显著概率。

表 3 是 16 个样本的神经网络模型和线性反演模型的预测值, 图 3 是模型预测值与实测值的散点图。从表 3 和图 3 可以看出, 神经网络模型的预测效果要远远好于线性回归的方法, 神经网络模型预测的最大绝对误差为 11.868 $\mu\text{g/L}$, 最大相对误差为 54.61%, 最小相对误差为 0.36%, 估算相对误差小于 30% 的有 13 个点, 占了总测试样本的 81.25%; 而线性回归的方法的最大误差为 82.60%, 估算相对误差小于 30% 的测试样点只占总测试样本的 50%。同时计算了线性反演模型预测值与实测值的 R_{RMSE} 和 R^2 值分别为 12.66 和 0.75, 其 R_{RMSE} 值远远大于神经网络模型的 4.25, 而 R^2 值远远小于神经网络模型的 0.96。神经网络模型的反演精度要远远高于线性回归模型。图 4 是由神经网络模型和 TM 数据生成的太湖悬浮物浓度分布图(TM 数据成像日期为 2003 年 11 月 13 日, 无云, 图像大小为 1930 \times 2034, 像元大小为 30 m)。从图 4 中可以看出, 太湖悬浮物浓度高的地区集中在湖心区, 而东太湖和贡湖地区的悬浮物浓度最低。从太湖南部到

表 3 悬浮物浓度预测值与实测值

Tab. 3 Predicted Chla Concentration and Measured Chla Concentration of 16 Test Samples

悬浮物浓度实测值	线性模型预测值	神经网络模型预测值	神经网络模型预测相对误差/%	线性模型预测的相对误差/%
8.04	11.52	7.07	12.01	43.27
9.44	17.20	14.60	54.61	82.21
10.44	9.97	14.64	40.24	4.51
11.44	18.60	14.64	28.01	62.56
13.08	10.64	14.64	11.93	18.64
14.64	26.73	12.81	12.5	82.60
17.6	19.15	14.63	16.89	8.80
22.2	28.72	18.20	18.0	29.37
26.48	11.54	14.61	44.82	56.43
30.56	25.92	29.72	2.75	15.18
33.28	35.74	31.72	4.70	7.40
37.00	34.86	38.22	3.30	5.80
47.8	28.18	42.74	10.59	41.05
57.4	33.23	57.61	0.36	42.11
68.96	56.79	63.36	8.12	17.65
77.6	48.09	77.20	0.51	38.03

北部,从东部到西部有3条明显高悬浮物浓度带,这是太湖的3条主要航道,由于航道上船体的搅动,使得悬浮物浓度明显高于其他地区。




图3 模型预测值与实测值散点图

Fig. 3 Predicted SS Concentration and Measured SS Concentration




图4 TM 图像和神经网络模型生成的2003年11月13日太湖悬浮物浓度分布图

Fig. 4 SS Distribution of Lake Taihu on Nov. 13, 2003

3 结语

神经网络模型由于其具备映射复杂关系的能力,非常适合光学特征复杂的二类水体水质参数的提取。本文通过构建一个具有4个输入节点、一个输出节点和一个隐含层的两层BP神经网络模型,实现了利用TM数据提取太湖水体的悬浮物浓度,反演精度要远远好于常规的线性模型。

BP神经网络模型自身存在局限性,它只是一个分类机而不是推理机,只能在一定范围之内达到非常高的反演精度,一旦超出这个范围,反演精度急剧下降,因此,它的泛化能力还需要进一步验证。

参 考 文 献

[1] Tassan S, dAlcala M R. Water Quality Monitoring by Thematic Mapper in Coastal Environments[J]. Remote Sens Environ, 1993, 45: 177-191
 [2] Tassan S. An Improved In-water Algorithm for the Determination of Chlorophyll and Suspended Sedi-

ment Concentration from Thematic Mapper Data in Coastal Waters[J]. Int J Remote Sensing, 1993, 14 (6): 1 221-1 229
 [3] Doerffer R, Fischer J. Concentrations of Chlorophyll, Suspended Matter, and Gelbstoff in Case II Waters Derived from Satellite Coastal Zone Color Scanner Data with Inverse Modeling Methods[J]. Journal of Geophysical Research, 1994, 99 (C4) : 7 457-7 466
 [4] Frette O, Jakob J, Stamnes S K. Optical Remote Sensing of Marine Constituents in Coastal Waters: A Feasibility Study[J]. Applied Optics, 1998, 37 (36) : 8 318-8 326
 [5] Harma P, Vepsalainen J. Detection of Water Quality Using Simulated Satellite Data and Semi-empirical Algorithms in Finland[J]. The Science of the Total Environment, 2001, 268: 107-121
 [6] Li Rongrong, Kaufman Y J, Gao Bocai. Remote Sensing of Suspended Sediments and Shallow Coastal Waters[J]. IEEE Trans on Geoscience and Remote Sensing, 2003, 41(3) : 559-566
 [7] Sathyendranath S, Platt T, Irwin B. A Multi Spectral Remote Sensing Study of Coastal Waters off Vancouver Island[J]. International Journal of Remote Sensing, 2004, 25(5) : 893-919
 [8] Harding J L W, Magnuson A, Mallonee M E. SeaWiFS Retrievals of Chlorophyll in Chesapeake Bay and the Mid-atlantic Bight[J]. Estuarine, Coastal and Shelf Science, 2005, 62: 75-94
 [9] International Ocean Colour Coordinating Group. Remote Sensing of Ocean Colour in Coastal, and Other Optically-Complex, Waters: IOCCG Report No. 3[R]. IOCCG Project Office, 2000
 [10] Hornik K, Stinchcombe M, White H. Multi-Layer Feedforward Networks are Universal Approximators[J]. Neural Networks, 1989, 2(5): 359-366
 [11] 况昶. 水色遥感理论模型的识别与求解途径探讨[D]. 北京: 清华大学, 1999
 [12] 刘兆德, 虞孝感, 王志宪. 太湖流域水环境污染现状与治理的新建议[J]. 自然资源学报, 2003, 18(4): 467-474
 [13] Vermote E F. Second Simulation of the Satellite Signal in the Solar Spectrum, 6S: An Overview[J]. IEEE Trans on Geoscience and Remote Sensing, 1997, 35(3) : 675-685
 [14] Martin T H, Howard B D, Mark H B. 神经网络设计[M]. 北京: 机械工业出版社, 2002

第一作者简介: 吕恒, 博士, 助理研究员, 现主要从事环境遥感和GIS应用方面的研究。
 E-mail: HengLu@niglas.ac.cn

(下转第735页)

Comparison of Adaptive Filter Arithmetics in Controlling Influence of Colored Noises

CUI Xianqiang¹ YANG Yuanxi² GAO Weiguang²

(1 Xi'an Research Institute of Surveying and Mapping, 1 Middle Yanta Road, Xi'an 710054, China)

(2 Institute of Surveying and Mapping, Information Engineering University, 66 Middle Longhai Road, Zhengzhou 450052, China)

Abstract: The state vector augmenting filter, influence function correcting filter and functional model fitting filter are all discussed as the frame of functional model compensation filter. And the covariance matrix adaptive estimate filter, robust M-M filter and adaptively robust filter are discussed in the content of stochastic model compensating filter. Based on the theories and models of filters, the advantages and disadvantages of each filter are analyzed, and an example is given.

Key words: colored noises; influence function; Kalman filter; adaptive estimation; kinematic GPS

About the first author: CUI Xianqiang, engineer, master, majors in GPS data processing and application.

E-mail: cuixianqiang@263.net

(上接第 686 页)

Quantitative Retrieval of Suspended Solid Concentration in Lake Taihu Based on BP Neural Net

LÜ Heng¹ LI Xinguo^{1,2} CAO Kai¹

(1 Nanjing Institute of Geography and Limnology, CAS, 73 East Beijing Road, Nanjing 210008, China)

(2 Graduate School of Chinese Academy of Sciences, 19A Yuquan Road, Beijing 100049, China)

(3 Department of City and Resource Science, Nanjing University, 22 Hankou Road, Nanjing 210093, China)

Abstract: A two-layer BP neural net model is constructed with four input nodes of TM1, 2, 3, 4 band reflectances, and one output node of suspended solid concentration(SSC) to retrieve SSC of Lake Taihu. The results demonstrated that BP neural net is very fit to quantitatively retrieve water quality of case II water with complex optic characteristic, and has much higher accuracy than the common linear model. A test was made and the results suggest that 13 had relative error (RE) RE of less than 30%, accounting for 81.25% of the total samples.

Key words: BP neural net; suspended solid concentration; Lake Taihu; quantitative retrieval

About the first author: LÜ Heng, Ph. D, assistant professor, majors in remote sensing of environment and GIS applications.

E-mail: HengLu@niglas.ac.cn