

基于 HJ-1A CCD 影像和 ELM 模型的 太湖叶绿素 a 预测研究

樊广利^{1,2}, 曹红业³, 徐晋²

(1. 西北大学 城市与环境学院, 陕西 西安 710127; 2. 西京学院 土木工程学院,
陕西 西安 710123; 3. 长安大学 地质工程与测绘学院, 陕西 西安 710064)

摘要: 以典型二类水体——太湖为例, 基于环境一号遥感影像, 构建了基于 ELM 模型的叶绿素 a 浓度预测模型, 将预测结果与传统的 BP 人工神经网络和支持向量机 SVM 进行了比较。研究表明: ELM 模型预测值与实测值之间的 R^2 高达 0.911 4, 而 BP 和 SVM 模型的 R^2 分别为 0.366 3 和 0.744 8, 均方根误差 RMSE 由 BP 模型和 SVM 模型的 3.728 8 $\mu\text{g/L}$ 和 2.132 4 $\mu\text{g/L}$ 降为 ELM 模型的 1.327 0 $\mu\text{g/L}$, ELM 模型的平均相对误差 MRE = 2.65%, 小于 BP 模型的 6.59% 和 SVM 模型的 3.89%; 与其他两种方法相比, ELM 模型反演太湖水体叶绿素 a 浓度精度更高, ELM 模型参数选择简单, 可以显著提高模型的学习速度, 不易陷入局部最优值, 具有更好的泛化性能; ELM 模型可以有效地应用于内陆水体叶绿素 a 浓度的预测。

关键词: 叶绿素 a 预测; HJ-1A CCD 影像; 极限学习机 (ELM); 内陆湖泊; 太湖

中图分类号: X832; X87

文献标识码: A

文章编号: 1672-643X(2020)05-0016-07

Prediction of chlorophyll a in Taihu Lake based on HJ-1A CCD imagery and ELM model

FAN Guangli^{1,2}, CAO Hongye³, XU Jin²

(1. College of Urban and Environmental Sciences, Northwest University, Xi'an 710127, China;

2. College of Civil Engineering, Xijing University, Xi'an 710123, China; 3. College of Geological
Engineering and Geomatics, Chang'an University, Xi'an 710064, China)

Abstract: Taking Taihu Lake as an example, a prediction model of chlorophyll a concentration based on extreme learning machine (ELM) model was constructed for the first time using the remote sensing images of Environment 1. The prediction results were then compared with those of the traditional BP artificial neural network and support vector machine (SVM) model. It was found that R^2 of ELM model reached as high as 0.911 4; however it only reached 0.366 3 of BP and 0.744 8 of SVM model. Root mean squared error (RMSE) of BP model and SVM model reduced from 3.728 8 $\mu\text{g/L}$ and 2.132 4 $\mu\text{g/L}$ to 1.327 0 $\mu\text{g/L}$ of ELM model. The mean relative error (MRE) of ELM model was 2.65%, which was lower than that of BP model (6.59%) and SVM model (3.89%). Compared with these two models, the ELM model has higher accuracy in the back analysis of chlorophyll a concentration in Taihu Lake. The parameter selection of ELM model is simple, which can significantly improve the learning speed of the model. This model has better generalization performance and it is not prone to local optimum. The experiment results show that ELM model can be effectively applied to the prediction of chlorophyll a concentration in inland lakes.

Key words: prediction of chlorophyll a; HJ-1A CCD imagery; extreme learning machine (ELM); inland lake; Taihu Lake

收稿日期: 2019-11-17; 修回日期: 2020-02-05

作者简介: 樊广利 (1975-), 男, 陕西富平人, 教授, 博士研究生, 主要研究方向为地理学、灾害学等。

通讯作者: 徐晋 (1976-) 男, 山东菏泽人, 博士研究生, 高级工程师, 主要从事建筑环境研究。

1 研究背景

由于我国人口密度大和过度开采利用水资源,目前正面临极为严重的水资源问题^[1],并且内陆湖泊水资源问题目前已经成为全球性的问题,水质监测和预警是水质评估和污染防治的主要依据^[2-3]。传统方法需要现场布设大量观察站点,具有耗时、劳动强度大、成本高的缺点,并且由于传统方法仅限于时间尺度和空间尺度,采集的数据只是部分河段的水质数据,只能以点带面研究整体情况。对于内陆湖泊这样的大面积水域,传统的野外采样-实验室分析方法难以达到大范围、迅速、长时间序列的动态水质监测要求^[4]。特别是对于太湖等水环境时空异质性较强的水体,传统方法的不足尤为突出。

由于遥感技术具有长期、实时和快速的水质监测的优势,甚至可以较为精确地探究传统方法不可解释的污染蔓延趋势^[5]。基于水体中不同材料成分的光谱反射率的差异,以及远程传感器接收的特征信息的差异,利用此技术可掌握大范围水域中不同物质组成的时空分布及长时间变化规律^[6]。

叶绿素a浓度是反映水体藻类关键的生物指标^[7-9]。然而目前对于水质较为复杂的内陆湖泊,建立适用性强、精确度高的水体叶绿素反演模型总是困难的。目前,主要有3种方法用于遥感监测内陆水域的叶绿素a浓度,即分析模型、经验模型和半经验或半分析模型^[10-12]。

叶绿素a浓度的遥感反演是一个具有大量不确定性的非线性过程^[13-14]。目前一些机器学习算法具有优秀的非线性近似等优点。被广泛应用于模式识别、特征提取、信号处理和非线性预测等领域,在水质遥感反演中具有一定的应用^[15-22]。BP(back propagation)神经网络模型在水质参数反演等领域已经得到了很多应用,但是BP人工神经网络训练速度慢,参数选择困难,很容易陷入局部极值。极限学习机(extreme learning machine, ELM)是一种全新的单隐层前向神经网络方法的机器学习模型^[23-24]。与传统的BP模型相比,ELM模型算法克服了传统模型训练时间长和过拟合等问题。同时,ELM的良好泛化能力也在实践中得到了验证。

环境一号(HJ-1)是我国首颗用于环境监测预警的遥感卫星,为水体叶绿素a浓度反演提供了巨大便利。但是目前利用HJ-1进行内陆水质监测的研究并不多,特别是水体叶绿素浓度遥感监测方面的应用更是较少。为了验证HJ-1卫星应用于

内陆湖泊叶绿素a浓度预测的应用潜力,本文以内陆典型湖泊——太湖为例,基于ELM模型和HJ-1A CCD传感器进行太湖叶绿素a浓度的预测,并交叉对比传统BP模型和支持向量机(support vector machine, SVM)模型。同时,将ELM模型应用于大气校正后的HJ-1A影像上,获取整个太湖湖面叶绿素a浓度的空间分布图,并细致分析反演结果以验证模型有效性。

2 研究区概况

太湖是我国第三大内陆淡水湖泊,整个湖面的面积为2 427.8 km²,横跨江浙两省,相邻较近的地市为无锡、湖州和苏州等城市。本文选取太湖作为研究区域,主要考虑到:太湖水体的叶绿素含量很高并且变化较大,适合于反演模型的建立及验证;另外太湖的污染状况一直受到广泛关注,是一直以来的研究热点,并且积累了许多历史数据可供参考。研究区太湖地理位置及采样点分布见图1。




图1 研究区太湖地理位置及采样点分布图

3 数据来源与预处理

3.1 HJ-1A 卫星影像介绍

HJ-1A卫星于2008年9月6日发射升空。卫星上搭载的传感器包含可见光和近红外光共4个波段,空间分辨率为30 m,成像宽度为360 km × 360 km,可以4 d快速实现地球上同一位置的再次重访。HJ-1A CCD传感器参数及取值如表1所示。

3.2 数据采集

分别于2016年7和10月组织人员对太湖水体

进行了 2 次实地采样,共采集了 48 个水样样本(采样点分布见图 1),野外测量和记录的参数包括采样点经纬度等信息,实验室采用分光光度法测试和分析样本叶绿素 a 浓度,各采样点叶绿素 a 浓度见表 2。将 48 个有效地面采集点数据进行随机抽样,分为训练样本数据和测试样本数据,其中 38 个数据用于建模,其余 10 个用于评定模型精度。

表 1 HJ-1A CCD 传感器参数及取值

参数	取值
光谱范围/ μm	0.43 ~ 0.52
	0.52 ~ 0.60
	0.63 ~ 0.69
	0.76 ~ 0.90
空间分辨率/m	30
幅宽/km	360
重访周期/d	4

表 2 太湖各采样点叶绿素 a 浓度

采样点序号	经度/(°)	纬度/(°)	Chl-a/($\mu\text{g} \cdot \text{L}^{-1}$)
1	120.0420	31.4572	55.7
2	120.1776	31.4597	50.0
3	120.3458	31.4281	35.4
4	120.2704	31.3711	41.1
5	119.9766	31.3307	54.0
...	...	...	...
47	120.2710	30.9466	48.0
48	120.2707	30.9466	58.5

3.3 遥感影像预处理

由于本研究直接获取的数据为几何粗校正的 HJ-1A CCD 影像,因此需要进行必要的的数据预处理工作,主要包括几何精校正、辐射定标和大气校正。

3.3.1 几何精校正 在湖面周边均匀选取明显地面控制点,采用二次多项式模型进行几何精校正(校正误差低于 1 个像元)。以消除或减弱影像成像过程中产生的几何畸变。影像的投影坐标采用 UTM 投影(通用横轴墨卡托投影)及 WGS-84 坐标系。

3.3.2 辐射定标 卫星地面接收站获取的是无量纲的 HJ-1A CCD 影像 DN 值,然而进行水质参数预测研究中使用的必须是绝对辐射亮度值。影像辐射定标的目的就是为将 DN 值根据定标公式转换为绝对辐射亮度值。

$$L(\lambda) = \text{Gain} \cdot DN + \text{Bias} \quad (1)$$

式中: $L(\lambda)$ 为卫星传感器入瞳处的绝对辐射亮度

值, $\text{W}/(\text{m}^2 \cdot \text{sr} \cdot \mu\text{m})$; DN 为卫星传感器的观测记录值(无量纲), Gain 和 Bias 分别为定标公式的两个系数,即增益值和偏移值。系数 Gain 和 Bias 的定标值如表 3 所示。

表 3 HJ-1A CCD 传感器绝对辐射定标系数

卫星载荷	波段	Gain 值	Bias 值
HJ-1A CCD	Band1	1.7715	7.3250
	Band2	1.6554	6.0737
	Band3	1.0281	3.6123
	Band4	1.0642	1.9028

3.3.3 大气校正 由于大气分子和气溶胶散射等因素的影响,影像所反映的不是真实的地物信息,因此必须对影像进行大气校正处理^[25]。本文利用 ENVI5.2 的 FLAASH 模型完成大气校正工作,获取大气校正后真实的反射率图像。

4 ELM 模型建立

4.1 ELM 基本原理

假设训练样本由 N 个不同的随机样本 $(\mathbf{x}_i, t_i)$ 组成,其中:

$$\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \quad (\mathbf{x}_i \in R^n) \quad (2)$$

$$t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \quad (t_i \in R^m) \quad (3)$$

隐层节点数目为 $\tilde{N}$ 且激励函数为 $g(x)$ 的神经网络模型为:

$$\sum_{i=1}^{\tilde{N}} \beta_i g(\mathbf{x}_j) = \sum_{i=1}^{\tilde{N}} \beta_i g(\mathbf{w}_i \cdot \mathbf{x}_j + b_i) = o_j \quad (4)$$

$$(j = 1, 2, \dots, N)$$

式中: $\mathbf{w}_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ 为输入节点与第 i 个隐层节点之间的权值; $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 为连接第 i 个隐层节点与输出节点之间的权值; $\mathbf{w}_i \cdot \mathbf{x}_j$ 为权值 $\mathbf{w}_i$ 与样本 $\mathbf{x}_j$ 的内积; b_i 为第 i 个隐层节点的偏置值。

隐层节点个数为 $\tilde{N}$ 且激励函数为 $g(x)$ 的神经网络模型可以完全逼近 N 个样本数据,即:

$$\sum_{i=1}^{\tilde{N}} \|o_j - t_j\| = 0 \quad (5)$$

存在 β_i 、 $\mathbf{w}_i$ 和 b_i , 得到:

$$\sum_{i=1}^{\tilde{N}} \beta_i g(\mathbf{w}_i \cdot \mathbf{x}_j + b_i) = t_j \quad (j = 1, 2, \dots, N) \quad (6)$$

也可以表示为如下矩阵形式:

$$H\beta = T \quad (7)$$

式中: $\mathbf{H}$ 为网络的隐层输出矩阵,可表示为:

$$\mathbf{H}(\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_{\tilde{N}}, b_1, b_2, \dots, b_{\tilde{N}}, \mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{\tilde{N}}) = \begin{bmatrix} g(\mathbf{w}_1 \cdot \mathbf{x}_1 + b_1) & g(\mathbf{w}_2 \cdot \mathbf{x}_1 + b_2) & \dots & g(\mathbf{w}_{\tilde{N}} \cdot \mathbf{x}_1 + b_{\tilde{N}}) \\ g(\mathbf{w}_1 \cdot \mathbf{x}_2 + b_1) & g(\mathbf{w}_2 \cdot \mathbf{x}_2 + b_2) & \dots & g(\mathbf{w}_{\tilde{N}} \cdot \mathbf{x}_2 + b_{\tilde{N}}) \\ \dots & \dots & \dots & \dots \\ g(\mathbf{w}_1 \cdot \mathbf{x}_{\tilde{N}} + b_1) & g(\mathbf{w}_2 \cdot \mathbf{x}_{\tilde{N}} + b_2) & \dots & g(\mathbf{w}_{\tilde{N}} \cdot \mathbf{x}_{\tilde{N}} + b_{\tilde{N}}) \end{bmatrix}_{N \times \tilde{N}} \quad (8)$$

由于通常情况下,隐层节点数目远远小于训练样本数目,使得公式(6)的模型难以实现,则在该模型中应加上误差 E ,即:

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T} + \mathbf{E} \quad (9)$$

式中: $\mathbf{E} = [e_1^T, e_2^T, \dots, e_N^T]^T_{N \times m_0}$

本文定义一个平方损失函数 J ,其表达式为:

$$J = \sum (\boldsymbol{\beta}_j g(\mathbf{w}_i, b_i, \mathbf{x}_j) - t_j) \quad (10)$$

其矩阵形式可以表示为:

$$J = (\mathbf{H}\boldsymbol{\beta} - \mathbf{T})^T (\mathbf{H}\boldsymbol{\beta} - \mathbf{T}) \quad (11)$$

其中最优化小二乘解为 $\hat{\boldsymbol{\beta}}$:

$$\|\mathbf{H}\hat{\boldsymbol{\beta}} - \mathbf{T}\| = \min_{\boldsymbol{\beta}} \|\mathbf{H}\boldsymbol{\beta} - \mathbf{T}\| \quad (12)$$

当矩阵 $\mathbf{H}$ 列满秩时,引入穆尔-彭罗斯广义逆矩阵求解参数 $\hat{\boldsymbol{\beta}}$,即:

$$\hat{\boldsymbol{\beta}} = \arg \min_{\boldsymbol{\beta}} \|\mathbf{H}\boldsymbol{\beta} - \mathbf{T}\| = \mathbf{H}^* \mathbf{T} \quad (13)$$

其中 $\mathbf{H}^* = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T$ 。

当矩阵 $\mathbf{H}$ 不是列满秩时,可以通过奇异值矩阵分解求解参数 $\hat{\boldsymbol{\beta}}$ 。

4.2 算法流程

ELM 算法通过如下步骤来进行网络权值的维度估计与判定:

- (1) 输入训练样本数据 $\{(\mathbf{x}_i, t_i)\}_{i=1}^N$, 并选择最佳隐藏层输出函数 $g(\mathbf{w}, b, \mathbf{x})$ 和隐层节点个数 L ;
- (2) 模型可以根据步骤(1)随机确定隐层节点参数,即权重值 $\mathbf{w}$ 和隐层节点偏移值 b ;
- (3) 计算网络模型隐层输出矩阵 $\mathbf{H}$;
- (4) 求解网络模型的最优最小二乘解 $\hat{\boldsymbol{\beta}}$;
- (5) 根据由步骤(3)和(4)计算的矩阵 $\mathbf{H}$ 和最优最小二乘解 $\hat{\boldsymbol{\beta}}$ 建立的最优模型算法预测测试样本数据。

网络输出权重值通过直接求解线性方程组来获得,这正是 ELM 算法简单、快速和高效的原因。

5 结果与分析

5.1 ELM 模型构建与检验

建立用于遥感反演的神经网络模型首先确定反

演的影响因素,然后确定网络输入层中神经元的数量。ELM 模型中的激励函数主要包括 Sigmoidal 函数、Sine 函数、Hardlim 函数、Triangular Basis 函数和 Radial Basis 函数。为了更有效地确定模型参数并选择激励函数,本文分别对上述 5 个函数进行了分析,并将隐含层节点的数量初始化为 5,将循环增加至 5 次,比较分析了不同激励函数和隐层节点数对水体叶绿素 a 反演的影响程度,其结果如图 2 所示。




图2 不同激励函数和隐层节点数对水体叶绿素 a 反演的测试误差

由图 2 可知,在节点数为 20 之后,径向基函数(radial basis)开始趋于稳定,在节点数为 10 之后, Sigmoidal 函数和 Sine 函数开始稳定,并且 RMSE 随着隐层节点数量的增加, Hardlim 和 triangular basis 函数的测试误差波动较大。并且径向基函数在节点数为 20 之后具有 0.7×10^{-4} 或更小的测试误差,与其他函数相比误差最小。

本文选择 38 个采样点的 HJ-1A CCD 波段比值 B4/B3 作为 ELM 模型的输入层,叶绿素 a 浓度作为输出层,构建预测模型,利用该构建模型对剩余 10 个验证样本进行预测,得到预测结果如图 3 所示。预测值与实测值的拟合程度 R^2 高达 0.911 4, 均方根误差 RMSE 仅为 $1.327 0 \mu\text{g/L}$ 。

5.2 模型对比

为对比验证 ELM 模型的反演精度,分别利用传统 BP 神经网络和 SVM 模型进行叶绿素 a 浓度反演。BP 模型相关参数参考相关文献[26]设置:隐层节点个数为 20,学习率设定为 0.01,计算步数最大值设定为 1 000 次,最小均方误差为 10^{-8} ,网络隐

含层激活函数使用“Sigmoid”函数,具体使用“logsig”函数,训练时使用“trainlm”函数;SVM 模型通过编写 SVMcgForRegress 函数来查找模型的最佳参数。选取高斯函数作为其核函数,核函数参数 γ 和回归惩罚系数均为 1,终止判据设置为 0.001。

与 ELM 模型反演过程相似,选择 38 个采样点 HJ-1A CCD 波段比值 B4/B3 作为模型的输入层,叶绿素 a 浓度作为输出层,构建预测模型。利用构建的模型分别对剩余 10 个验证样本进行预测,得到其预测结果如图 4、5 所示。由图 4、5 可知,BP 模型的预测值与实测值的拟合度 R^2 仅为 0.366 3,均方根误差 $RMSE$ 为 3.728 8 $\mu\text{g/L}$;SVM 模型的拟合度略高于 BP 模型($R^2=0.744\ 8$),均方根误差比 BP 模型略低($RMSE=2.132\ 4\ \mu\text{g/L}$)。总体来看,SVM 模型的预测精度略高于传统 BP 神经网络模型

的精度。

对 3 种模型叶绿素 a 浓度反演结果的相对误差进行比较,如表 4 所示。由表 4 可见,ELM 神经网络模型反演精度优于 BP 和 SVM 模型,ELM 反演结果的最大相对误差为 4.60% (序号 4),而 BP 和 SVM 神经网络模型的最大相对误差分别为 19.04% 和 8.67%。另外,通过计算表明,ELM 模型预测样本的平均相对误差 $MRE=2.65\%$,小于 SVM 和 BP 模型的平均相对误差(BP 和 SVM 模型的 MRE 值分别为 6.59% 和 3.89%)。

不难得出如下结论,针对太湖区域叶绿素 a 浓度反演,ELM 模型与 BP 和 SVM 模型相比较而言,其整体性能更优。BP 神经网络模型结构比 ELM 模型简单,但预测精度不如 ELM 模型,BP 模型算法的参数需要在运行过程中不断调整。




图3 ELM 模型的验证结果




图4 BP 模型的验证结果




图5 SVM 模型的验证结果

表4 3 种模型 Chl-a 浓度反演结果的相对误差比较

序号	实测值/ ($\mu\text{g}\cdot\text{L}^{-1}$)	BP 模型		SVM 模型		ELM 模型	
		反演值/($\mu\text{g}\cdot\text{L}^{-1}$)	相对误差/%	反演值/($\mu\text{g}\cdot\text{L}^{-1}$)	相对误差/%	反演值/($\mu\text{g}\cdot\text{L}^{-1}$)	相对误差/%
1	40.0	38.3	4.25	41.9	4.53	38.8	3.09
2	40.6	38.8	4.43	41.2	1.46	41.4	1.93
3	43.5	41.5	4.60	42.5	2.35	43.0	1.16
4	41.5	49.4	19.04	43.1	3.71	43.5	4.60
5	44.0	44.1	0.23	42.0	4.76	42.1	4.51
6	48.0	45.2	5.83	47.6	0.84	46.9	2.35
7	46.8	48.4	3.42	49.1	4.68	48.8	4.10
8	49.0	45.5	7.14	50.0	2.00	47.9	2.30
9	48.1	50.9	5.82	51.1	5.87	47.9	0.42
10	53.9	47.9	11.13	49.6	8.67	55.0	2.00
平均值			6.59		3.89		2.65

5.3 太湖叶绿素 a 浓度反演

本文基于 ELM 模型结合 HJ-1A CCD 影像反演整个研究区域叶绿素 a 浓度,反演结果如图 6 所示。图 6 中绿色区域为叶绿素高浓度分布区,蓝色

区域为叶绿素低浓度分布区。不难发现,从空间分布上看,太湖的叶绿素 a 浓度分布不均,其总体上呈现从北向南递减的趋势,太湖的中南部湖区(图 6 中深蓝色区域)是全湖叶绿素浓度最低的区域,连

片分布于太湖的中部和离岸较远的南部区域,水面较为开阔。叶绿素a高浓度区域主要集中分布在竺山湖、梅梁湖和贡湖3个区域,浓度高于 $70\text{ }\mu\text{g/L}$,最高的区域出现在梅梁湾的西入口、竺山湾西沿岸区、两湾之间以及太湖西部的靠岸边区域,三者的叶绿素a浓度甚至大于 $100\text{ }\mu\text{g/L}$ 。根据湖泊水库监测标准,竺山湖和梅梁湖在叶绿素a浓度这一评价指标上太湖达到V类水质的标准。竺山湾和梅梁湾因为受人类活动以及外源性营养盐的输入等因素的影响成为太湖水华最严重的区域。东太湖(图6中灰色部分)的叶绿素a浓度呈现较高的水平,可能是受该区域丰富的沉水植物和挺水植物所致,其反射光谱特征与蓝藻极为相似,并不能准确表征该地区水体的叶绿素a浓度信息,但是反演的结果不能代表水体叶绿素浓度,因此本文根据相关研究对该区域进行了掩膜处理^[27]。此外在湖的大部分边缘区域即与陆地交接处,叶绿素a浓度也偏高,这一方面是由于水华易在岸边带堆积,另一方面与岸边带的芦苇分布以及湖边陆地植被干扰有关。

研究表明,应用遥感技术可以掌握大范围的水质指标动态变化,随着国内外遥感数据源的增多,遥感技术为太湖叶绿素a浓度进行长时间序列的监测提供了便利。近年来,随着太湖流域环境的不断恶化,更应该加强太湖的水质监测,应用本文提出的遥感反演模型能够大大提高水质监测效率。




图6 太湖湖面叶绿素a浓度空间分布反演结果

6 结论

(1)以内陆典型湖泊-太湖为例,基于ELM模

型和HJ-1A CCD传感器进行太湖叶绿素a浓度的预测,并交叉对比了BP模型和SVM模型的反演结果。将ELM模型应用于大气校正后的HJ-1A影像上,获取整个太湖湖面叶绿素a浓度的空间分布图。研究表明,与传统的BP和SVM模型反演结果相比,ELM具有更高的预测精度。2016年夏季,太湖高浓度叶绿素a主要集中在梅梁湾的西入口、竺山湾西沿岸区、两湾之间以及太湖西部的靠岸边区域。

(2)为ELM模型在内陆湖泊水质遥感监测方面的应用做了尝试性探索研究,说明将ELM模型应用于湖泊水质参数遥感监测是可行的、有效的,后期的研究中再继续获取水体光谱和水质参数等数据,以期继续提高水质参数业务化遥感预测精度。

本文仅研究了太湖区域,为了进一步验证该模型的广泛性,下一步研究应将该模型应用于更加广泛的区域,以期为内陆湖泊水质遥感监测提供便利。

参考文献:

- [1] 何向东. 水资源管理中存在的问题及解决对策[J]. 能源与节能, 2017(8):110-111.
- [2] 孙改,徐德兰,周颖,等. 基于粒子群算法和离差平方和法的奎河水质评价[J]. 水利发展研究,2017,17(3):58-62.
- [3] 朱江山,王得玉. MERIS 遥感图像的太湖叶绿素浓度反演研究[J]. 计算机技术与发展,2017,27(4):192-195.
- [4] 彭保发,陈哲夫,李建辉,等. 基于GF-1影像的洞庭湖区水体水质遥感监测[J]. 地理研究,2018,37(9):1683-1691.
- [5] 黄帅. 基于资源3号影像的阳澄湖围网区自动提取算法研究[D]. 合肥:安徽大学, 2017.
- [6] 朱利,姚延娟,吴传庆,等. 基于环境一号卫星的内陆水体水质多光谱遥感监测[J]. 地理与地理信息科学, 2010,26(2):81-84.
- [7] 齐凌艳,黄佳聪,高俊峰,等. 洪泽湖叶绿素a浓度的时空变化特征[J]. 湖泊科学, 2016,28(3):583-591.
- [8] 万修志. 提取测定淡水藻中叶绿素a的方法研究[D]. 济南:山东建筑大学, 2011.
- [9] 朱云芳,朱利,李家国,等. 基于GF-1WV影像和BP神经网络的太湖叶绿素a反演[J]. 环境科学学报, 2017,37(1):130-137.
- [10] 顾万花. 基于遥感的淀山湖水体叶绿素a浓度估算研究[D]. 上海:复旦大学, 2011.
- [11] 孙绍杰. 基于GOCI的太湖水体叶绿素a浓度估算及其昼变化特征分析[D]. 南京:南京大学, 2013.
- [12] 丰明博,牛铮. 基于经验模型的Hyperion数据植被叶绿素含量反演[J]. 国土资源遥感,2014,26(1):71-77.

- [13] 李大千. 鄱阳湖叶绿素 a 浓度遥感反演研究[D]. 赣州:江西理工大学, 2016.
- [14] 顾万花. 基于遥感的淀山湖水体叶绿素 a 浓度估算研究[D]. 上海:复旦大学, 2011.
- [15] 王琦, 孟伟, 马云峰, 等. 利用 BP 神经网络预测大伙房水库叶绿素 a 质量浓度[J]. 东北大学学报(自然科学版), 2013, 34(12): 1792 – 1795.
- [16] 徐逸, 董妍妍, 王俊杰. 4 种机器学习模型反演太湖叶绿素 a 浓度的比较[J]. 水生态学杂志, 2019, 40(4): 48 – 57.
- [17] 李峰, 纪道斌, 刘德富, 等. 基于 BPNN 的三峡水库神农溪叶绿素 α 浓度预测[J]. 环境科学与技术, 2015(12Q): 23 – 27.
- [18] 易仲强. 基于 ANN 和 SVM 的三峡水库香溪河库湾富营养化预测研究[D]. 宜昌:三峡大学, 2011.
- [19] 吕恒, 江南, 李新国. 内陆湖泊的水质遥感监测研究[J]. 地球科学进展, 2005, 20(2): 185 – 192.
- [20] BUCKTON D, O'MONGAIN E, DANAHER S. The use of neural networks for the estimation of oceanic constituents load on the MERIS instrument[J]. International Journal of Remote Sensing, 1999, 20(9): 1841 – 1851.
- [21] GROSS L, THIRIA S, FROUIN R. Applying artificial neural network methodology to ocean color remote sensing[J]. Ecological Modelling, 1999, 120(2 – 3): 237 – 246.
- [22] KEINER L E, YAN Xiaohai. 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.
- [23] HUANG Guangbin, ZHU Qinyu, SIEW C K. Extreme learning machine: Theory and applications[J]. Science Direct, 2006, 70(1 – 3): 489 – 501.
- [24] HUANG Guangbin, BABRI H A. Upper bounds on the number of hidden neurons in feedforward networks with arbitrary bounded nonlinear activation functions[J]. IEEE Transactions on Neural Networks, 1998, 9(1): 224 – 229.
- [25] 李正强, 陈兴峰, 马龙天, 等. 光学遥感卫星大气校正研究综述[J]. 南京信息工程大学学报(自然科学版), 2018, 10(1): 6 – 15.
- [26] 楼顺天, 施阳. 基于 MATLAB – 神经网络的系统分析与设计[M]. 西安:西安电子科技大学出版社, 1998.
- [27] 张方方. 基于软分类的太湖水体叶绿素 a 浓度遥感反演与长时间序列分析[D]. 上海:华东师范大学, 2014.

(上接第 15 页)

- [31] ABILEAH R, VIGNUDELLI S. A completely remote sensing approach to monitoring reservoirs water volume[J]. International Water Technology Journal, 2011, 1(1): 59 – 72.
- [32] DEVRIES B, HUANG C G, LANG W M, et al. Automated quantification of surface water inundation in wetlands using optical satellite imagery[J]. Remote Sensing, 2017, 9(8): 807 – 828.
- [33] 吴红波, 郭忠明, 陈安安, 等. 坡度和粗糙度对 ICESat – GLAS 回波特征及其光斑脚点高程误差的影响研究[J]. 地理与地理信息科学, 2016, 32(4): 30 – 37.
- [34] MUNYANEZA O, WALI U G, UHLENBROOK S, et al. Water level monitoring using radar remote sensing data: Application to Lake Kivu, central Africa[J]. Physics and Chemistry of the Earth, Parts A/B/C, 2009, 34(13): 722 – 728.
- [35] CRAIG M, NATASCHA K, SIETSE L, et al. Slope estimation from ICESat/GLAS[J]. Remote Sensing, 2014, 6(10): 10051 – 10069.
- [36] LI Xiaolu, XU Kai, XU Lijun. Surface slope and roughness measurement using ICESat/GLAS elevation and laser waveform[J]. Measurement Science & Technology, 2016, 27(9): 95202 – 95210.
- [37] QI Miaomiao, YAO Xiaojun, LI Xiaofeng, et al. Spatiotemporal characteristics of Qinghai Lake ice phenology between 2000 and 2016[J]. Journal of Geographical Sciences, 2019, 29(1): 115 – 130.