

文章编号: 1007-4619 (2002) 01-0040-05

基于人工神经网络的一类水域叶绿素-a 浓度反演方法

张亭禄, 贺明霞

(青岛海洋大学 海洋遥感研究所, 海洋遥感教育部重点实验室, 山东 青岛 266003)

摘要: 介绍了一种基于神经网络的海中一类水域叶绿素反演方法。神经网络是3层的反向传输神经网络。其结构是输入层有4个节点, 它们分别对应4个波段 412 nm, 443 nm, 490 nm, 510 nm 的遥感反射比与 555 nm 波段遥感反射比的比值, 隐含层有5个节点, 输出层一个节点对应于叶绿素浓度。该神经网络的训练和试验样本集来自 SeaBAM 的数据集。数据集中的 919 个站位的 70% (644 个) 用于训练, 30% (275 个) 用于测试。结果表明, 该方法的精度优于被广泛采用的三次经验方法。

关键词: 叶绿素浓度; 反演; 人工神经网络

中图分类号: TP79/P71 **文献标识码:** A

1 引言

目前, 有多种方法用于海中叶绿素的反演。如, 传统的经验方法^[1], 它利用现场测量的数据去拟和三次或二次多项式。该方法被认为是目前精度最高的一类水域的算法, 但对于复杂的水域(二类水域)

该方法失效; 半分析算法, 有 Carder 算法^[2], Garver/Siegel 算法^[3]; 人工神经网络方法^[4], Schiller & Doeffler 利用反向传输神经网络用于海中有关成分的反演, 其训练数据来自 Monte Carlo 模拟。模拟结果表明, 人工神经网络用于反演水中有关成分有很好的性能。无论是半分析方法还是 Schiller & Doeffler 的人工神经网络方法, 目前最大障碍是缺乏

表 1 SeaBAM 数据的有关信息^[1]

Table 1 Information about SeaBAM database

数据名称	提供者	海域	时间	数据数	海水类型
BBOP92-93	D. Siegel	Sargasso Sea	Monthly, 1992-1993	72	1
BBOP94-95	D. Siegel	Sargasso Sea	Monthly, 1994-1995	67	1
WOCE	J. Marra	50°S-13°N, 88°-91°W 10°S-30°N, 18°-37°W	March 1993 April 1993	70	1
EQPAC	C. Davis	0, 140°W	March, Sept. 1992	126	1
NABE 1	C. Trees	46°-59°N, 17°-20°W	May 1989	72	1
NABE 2	C. Davis	46°N, 19°W	April 1989	40	1
CARDER	K. Carder	North Atlantic Pacific Gulf Mexico Arabian Sea	Aug. 1991 July 1992 April 1993 Nov. 1994, June 1995	87	1
CALCOFI	G. Mitchell	California Current	Aug. 1993-July 1996	303	1
MOCE 1	D. Clark	Monterey Bay	Sept. 1992	8	1
MOCE 2	D. Clark	Gulf California	April 1993	5	1
North Sea	R. Doeffler	52°-55°N, 0°-8°E	July 1994	10	2
Chesap. Bay	L. Harding	~37°N, 75°W	April, July 1995	9	2
Canadian Arctic	G. Cota	~74.38°N, 95°W	Aug. 1996	8	1
AMT	G. Moore	50°N-50°S	Sept. 1995, April 1996	42	1
Total				919	

收稿日期: 2000-11-02; 修订日期: 2001-01-03

基金项目: 国家自然科学基金(49776288)项目资助。

作者简介: 张亭禄(1965-), 男, 副教授, 1987年毕业于青岛海洋大学物理系海洋物理专业。主要从事海水遥感和海洋光学的基础研究及教学。发表论文近 20 篇。

可靠的固有光学参数的模型。

本文利用反向传输神经网络，现场测量的遥感反射比数据作为该神经网络的训练样本集，另一部分现场测量的遥感反射比数据作为试验样本集。其结果表明，本文所用的方法优于传统的经验方法。

2 数据集

本研究所使用的数据来源于 SeaBAM (SeaWiFS Bio-optical Algorithm Mini-Workshop)^[1]。它共有 919 个站位的数据。其叶绿素浓度的分布范围为 0.019—32.97 mg/m³，大多数的站位属于一类水域，大约 20 个属于二类水域。表 1 为这些数据的有关信息。

3 人工神经网络方法

3.1 原理

本研究利用 3 层反向传输神经网络^[5]。第一层为输入层，中间层为隐含层，第 3 层为输出层。各层的神经元之间形成互连接，各层内的神经元之间没有连接。图 1 为一简单的人工神经网络的结构。输入层有 3 个节点，隐含层有 5 个节点，输出一个。




图 1 一个简单的人工神经网络的结构

Fig. 1 The structure of a simple artificial neural network

对于输入层神经元，其输出和输入相同。隐含层的神经元的输出为：

$$O_h = F(IW^h)$$

输出层的神经元的输出为：

$$O_o = F(O_h^T W^o)$$

其中： $F(X) = \frac{1}{1 + e^{-X}}$ 。I 为输入层的输入，W^h 为隐含层的权重，W^o 为输出层的权重，O_h^T 为 O_h 的转置。

当对该网络进行训练时，首先有若干组训练样本，其中的每个样本由输入和理想输出组成。当网络的所有实际输出与理想输出一致时，训练结束。

否则，通过修改权重，使网络的实际输出与理想输出一致。

3.2 神经网络的训练及应用

把 SeaBAM 中的数据随机地分成两部分，比例为 70% 和 30%。其中的 70% 作为神经网络系统的训练样本，其余 30% 作为试验样本集。SeaBAM 中提供了 5 个可见波段 (412 nm, 443 nm, 490 nm, 510 nm, 555 nm) 的遥感反射比及其对应的叶绿素浓度值。

为了比较所导出的叶绿素浓度的精度，首先定义两个参数：

均方根误差：

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (\log_{10}(P_i^D) - \log_{10}(P_i^M))^2}{N}}$$

这里 P 是叶绿素浓度，上标 ‘D’ 和 ‘M’ 分别表示导出的叶绿素浓度和实测值或模型输入值。在本研究中由于叶绿素浓度的分布范围很大，在计算均方根误差前，先对其取对数，这样更合理。

相关系数 (R²) 为线性的 Pearson 相关系数。

我们选用 3 层的反向传输神经网络系统。很显然，输出层只有一个节点，它对应于叶绿素浓度。输入层和隐含层的节点数由如下的实验确定。

(1) 首先把 5 个可见光波段的遥感反射比分成不同的组合 (表 2 列出了这些组合)，把它们分别作为神经网络的输入。然后，比较反演出的叶绿素的精度，找出最佳的波段组合。

表 2 波段的组合

Table 2 Combinations of the remote sensing reflectances at different wavelengths

名称	个数	输入	输出
Case-1	5	R _{rs} 412, R _{rs} 443, R _{rs} 490, R _{rs} 510, R _{rs} 555	叶绿素浓度
Case-2	4	R _{rs} 443, R _{rs} 490, R _{rs} 510, R _{rs} 555	叶绿素浓度
Case-3	4	R _{rs} 412/R _{rs} 555, R _{rs} 443/R _{rs} 555, R _{rs} 490/R _{rs} 555, R _{rs} 510/R _{rs} 555	叶绿素浓度
Case-4	3	R _{rs} 443/R _{rs} 555, R _{rs} 490/R _{rs} 555, R _{rs} 510/R _{rs} 555	叶绿素浓度
Case-5	2	R _{rs} 490/R _{rs} 555, R _{rs} 510/R _{rs} 555	叶绿素浓度

(2) 为了确定最佳的隐含层的节点数，对于 (1) 中的每种组合，分别计算不同隐含层节点数 (5—50) 下对应的叶绿素的反演精度。

3.3 与经验算法的比较

对于一类水域，研究结果显示^[1]经验算法的精

度优于半分析方法。而在经验算法中,3次的经验算法好于其它形式的算法。因此,本研究中,为了检验本算法的反演精度,我们仅把3次的经验算法的结果与神经网络比较。3次的经验算法列于表3。

表 3 3次的经验算法

Table 3 Cubic empirical algorithms

算法	函数形式	波段比
POLDER	$C=10(a_0+a_1R+a_2R^2+a_3R^3)$	$R=\log(R_{rs443}/R_{rs555})$
CalCOFI 2 band cubic	$C=10(a_0+a_1R+a_2R^2+a_3R^3)$	$R=\log(R_{rs490}/R_{rs555})$
Morel-3	$C=10(a_0+a_1R+a_2R^2+a_3R^3)$	$R=\log(R_{rs443}/R_{rs555})$
OC-2	$C=10(a_0+a_1R+a_2R^2+a_3R^3)+a_4$	$R=\log(R_{rs490}/R_{rs555})$
OC-2B	$C=10(a_0+a_1R+a_2R^2+a_3R^3)+a_4$	$R=\log(R_{rs443}/R_{rs555})$
OC-4	$C=10(a_0+a_1R+a_2R^2+a_3R^3)+a_4$	$R=\log([R_{rs443}>R_{rs490}>R_{rs510}]/R_{rs555})$

4 实验结果

(1) 图2和图3是为确定神经网络系统的结构进行的实验结果。在图中不同类型的曲线代表不同的波段组合。由图2,图3看出,Case-3对应的组合有较高的相关系数和较小的均方根误差。另外,当隐含层节点数等于5时,Case-3所对应的组合有最大的相关系数和最小的均方根误差。因此,最佳的神经网络系统的结构为:4个输入节点,5个隐层节点,1个输出节点。




图 2 相关系数随 ANN 结构的变化

Fig. 2 Variation of correlate coefficient with the structure of ANN

把训练样本输入到最佳神经网络系统中,训练完成后,再把试验样本输入训练好的网络中。图4和图5分别对应训练样本和试验样本的输出结果。表4是部分试验样本5个波段遥感反射比的数据及其对应的现场测量叶绿素浓度和神经网络反演




图 3 均方根误差随神经网络结构的变化

Fig. 3 Variation of RMSE with the structure of ANN

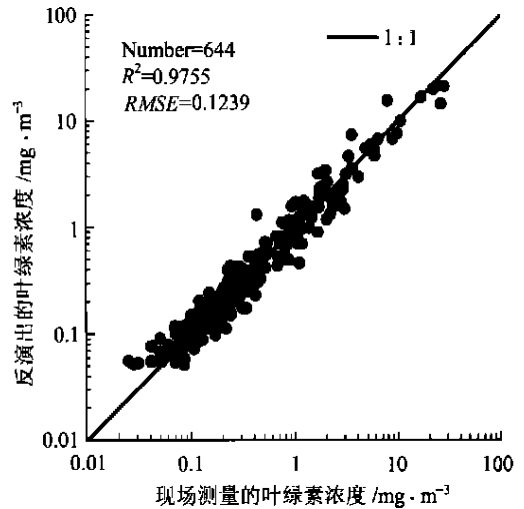


图 4 训练数据集的输出结果

Fig. 4 The output of training data set

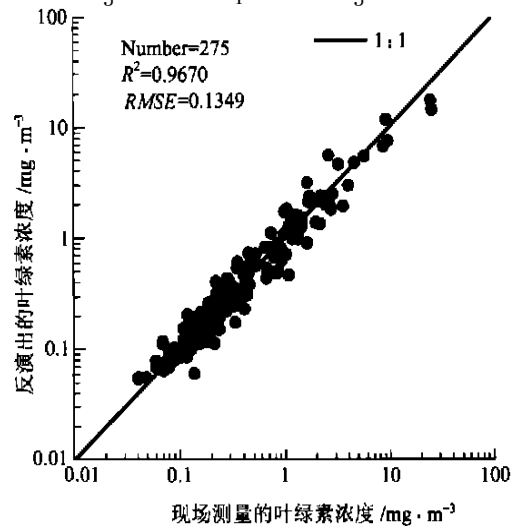


图 5 试验数据集的输出结果

Fig. 5 The output of testing data set

的叶绿素浓度。在此表中,现场测量的叶绿素浓度用 $Chl-m$ 表示,神经网络反演的叶绿素浓度由 $Chl-d$ 表示。

表4 部分试验样本的遥感反射比数据及其对应的叶绿素浓度

Table 4 Part of remote sensing reflectances and their chlorophyll concentrations

$R_{rs,412}$	$R_{rs,443}$	$R_{rs,490}$	$R_{rs,510}$	$R_{rs,555}$	$Chl-m$	$Chl-d$
0.010401	0.0094035	0.0066653	0.0036668	0.0014600	0.080	0.076
0.007517	0.0073350	0.0062610	0.0041490	0.0019420	0.18	0.15
0.002533	0.0022031	0.0028697	0.0027699	0.0021766	1.18	1.54
0.002062	0.0015554	0.0017901	0.0023156	0.0020491	2.27	2.41
0.003573	0.0031470	0.0030090	0.0026130	0.0016560	0.46	0.49
0.001829	0.0016011	0.0016352	0.0017081	0.0014386	1.28	1.46
0.002295	0.0022861	0.0028650	0.0026656	0.0023048	1.37	1.60
0.002120	0.0016059	0.0018571	0.0022833	0.0021097	2.93	2.52
0.014076	0.0113980	0.0070097	0.0033329	0.0013430	0.049	0.056
0.004799	0.0047020	0.0047627	0.0034997	0.0017405	0.29	0.25

(2) 把 30% 用于神经网络试验样本的数据, 输入到表 3 所列出的经验算法中, 计算出叶绿素浓度。然后, 计算出与实测值相对应的相关系数和均方根

误差。由神经网络和经验算法得出的相关系数和均方根误差见表 5。可见, 神经网络方法得出的相关系数最大, 而均方根误差最小。

表5 各种算法的相关系数及均方根误差比较

Table 5 Comparison of different algorithms

算法	CalCOFI	Morel-3	OC-2	OC-2B	OC-4	POLDER	本算法
RMSE	0.1677	0.1888	0.1829	0.1955	0.1640	0.3009	0.1349
R^2	0.9623	0.9534	0.9561	0.9526	0.9629	0.9536	0.9676

5 误差分析

遥感手段所获取数据中的噪声源非常复杂, 难以描述。为此, 对本算法误差分析时, 我们假定噪声是随机的。另外, 我们假定随机噪声有两类, (1) 每个波段的遥感反射比具有相同比例的噪声, 但不同样本噪声的比例是随机的; (2) 不同样本及不同波段的遥感反射比的噪声比例是随机的。

很明显, 对于第一种噪声源不影响本算法的精度。因为, 本算法的输入是四个波段 412 nm, 443 nm, 490 nm, 510 nm 的遥感反射比与 555 nm 波段遥感反射比的比值。作比值计算后, 噪声项被去掉。

对于第 2 种噪声源, 我们做如下的实验检验本算法的误差。把训练样本集中不同波段及不同样本的遥感反射比数据分别叠加 $\pm 3\%$ 和 $\pm 5\%$ 的随机噪声。然后, 对每一样本作比值运算, 最后把所有样本输入到本研究所得出的算法中, 计算输出结果(表 6)。由表 6 可见, 当输入噪声为 $\pm 3\%$ 和 $\pm 5\%$ 时, 反演出的叶绿素浓度的均方根误差分别增加 5% 和 10%。由此可知, 本算法是稳定的, 输入误差与反演

出的误差幅值相近。

表6 输入噪声对反演误差的影响

Table 6 The influence of input noise on the derived errors

噪声	0	$\pm 3\%$	$\pm 5\%$
RMSE	0.1349	0.1416	0.1487
R^2	0.9676	0.9656	0.9618

6 结论

(1) 建立了对应于该数据集的最佳人工神经网络系统, 其结构为: 4 个输入(对应于 4 个波段 412 nm, 443 nm, 490 nm, 510 nm 的遥感反射比与 555 nm 波段遥感反射比的比值), 5 个隐层节点, 一个输出节点, 对应叶绿素浓度。

(2) 本文所介绍的算法优于目前普遍采用的 3 次经验算法。

(3) 本算法具有很高的计算速度, 可以用于一类水域反演的在轨道法。

参考文献 (References)

- [1] O'Reilly J E et al. Ocean Color chlorophyll algorithms for SeaWiFS

- [J]. *J. G. R.*, 1998, **103**: 24937—24953.
- [2] Carder K L, Hawes S K, Lee Z P *et al.* Algorithm Theoretical Basis Document: Case 2 Chlorophyll a [R], 1999, ATBD-MOD-19.
- [3] Garver S A, Siegel D A. Inherent optical property inversion of ocean color spectra and its biogeochemical interpretation. 1. Time series from Sargasso Sea [J]. *J. G. R.*, 1997, **102**: 18607—18625.
- [4] Schiller H, Doerffer R. Neural network for emulation of an inverse model—operational derivation of Case II water properties from MERIS data [J]. *Int. J. Remote Sensing*, 1999, **20**: 1735—1746.
- [5] Hu S R, Yu S B, Dai K. An Introduction to Neural Network [M]. Changsha: National University of Defence Technology Press, 1992. [胡守仁, 余少波, 戴葵. 神经网络导论[M]. 长沙: 国防科技大学出版社, 1992.]

A Method to Retrieve the Oceanic Chlorophyll-a Concentrations in Case I Water Based on Artificial Neural Network

ZHANG Ting-lu, HE Ming-xia

(*Ocean Remote Sensing Laboratory of Ministry of Education of China, Ocean Remote Sensing Institute, Ocean University of Qingdao, Qingdao 266003, China*)

Abstract: A method to retrieve the oceanic chlorophyll concentrations in Case I water based on Artificial Neural Network (ANN) is presented. The ANN used in this paper is a three-layer feed forward back-propagation network which has 4 neurons in the input layer (corresponding to the ratios of the remote sensing reflectances at 4 wavelengths: 412 nm, 443 nm, 490 nm, 510 nm to the remote sensing reflectance at 555 nm), 5 neurons in the hidden layer and one neuron for the output layer (Corresponding to chlorophyll concentration). The training data set and testing data set of the ANN come from SeaBAM data base. 70% of the 919 stations in SeaBAM was used for training data set, the other 30% used for testing data set. At the end, the retrieved results from ANN and from the empirical algorithms were compared. The results show that the accuracy of the ANN is better than the cubic empirical algorithms used widely.

Key words: chlorophyll concentrations; retrieval; artificial neural network