

doi:10.3799/dqkx.2017.552

# 基于 WorldView-02 高分影像的 BP 和 RBF 神经网络遥感水深反演

郑贵洲, 乐校冬, 王红平, 花卫华

中国地质大学信息工程学院, 湖北武汉 430074

**摘要:** 遥感水深反演是水深测量的一种重要技术和手段。以美济礁水深反演为例, 选择 WorldView-02 高分影像为数据源, 在辐射定标和大气校正的基础上, 构建 BP(Back Propagation)和 RBF(Radial Basis Function)人工神经网络水深反演模型, 以遥感影像 8 个波段为输入层, 通过 tansig、logsig、高斯函数和 purelin 函数变换实现从输入层到隐含层、隐含层到输出层的转换, 以便反演水深。最后对反演水深与实测水深采用回归分析, 求解决定系数(coefficient of determination,  $R^2$ )、平均决定误差(Mean Absolute Error, MAE)、均方根误差(Root Mean Square Error, RMSE)等进行比较, 评价 2 种模型的精度。结果表明, RBF 神经网络模型结构更简单, 对样本要求更低, 反演精度达到 0.995, 更适合遥感水深反演。

**关键词:** 遥感; WorldView-02; 水深反演; BP 神经网络; RBF 神经网络。

**中图分类号:** P237

**文章编号:** 1000-2383(2017)12-2345-09

**收稿日期:** 2017-01-24

## Inversion of Water Depth from WorldView-02 Satellite Imagery Based on BP and RBF Neural Network

Zheng Guizhou, Le Xiaodong, Wang Hongping, Hua Weihua

Faculty of Information Engineering, China University of Geosciences, Wuhan 430074, China

**Abstract:** The inversion of water depth from remote sensing imagery is an important technology of depth measurement. In this paper, on the basis of radiometric calibration and atmospheric correction, BP(back propagation)and RBF(radial basis function) neural networks were built to retrieve water depth from WorldView-02 high-resolution satellite imagery in Mischief reef. Band 1 to band 8 of satellite imagery were used as the input data of the neural networks. Then, they were converted from input layer to hidden layer and from the hidden layer to output layer with tansig, logsig, Gaussian and purelin functions. Finally, the accuracy of the two models was evaluated by  $R^2$  (coefficient of determination), MAE(mean absolute error), RMSE(root mean square error) and the regression analysis between retrieved water depth and ground measured water depth. The results show that RBF neural network has simpler model structure, and lower requirement of samples. Besides, its retrieval accuracy reaches 0.995. Therefore, RBF neural network is more suitable for the inversion of water depth.

**Key words:** remote sensing; WorldView-02; water depth inversion; BP neural network; RBF neural network.

## 0 引言

目前,传统利用船只探测水深的方法已不能满足科技时代对探测水深精确、实时的要求(党福星和丁

谦,2003)。随着遥感技术的发展,利用遥感反演水深已成为水深探测的新道路(Wang *et al.*,2007)。它很好的克服了传统方法的局限性,并具有时间短、范围广、成本低的优点(Su *et al.*,2015)。最初的遥感反演水深研究主要是通过建立水深与反射率的线性关系反演

**基金项目:** 巴拉望岛附近海域基础地质调查遥感解译。

**作者简介:** 郑贵洲(1963—),男,教授,博士,主要从事地理计算与空间分析、三维地理信息系统及地学模拟、空间信息应用工程、资源与环境遥感研究。ORCID:0000-0002-2890-6395.E-mail:zhenggz@cug.edu.cn

**引用格式:** 郑贵洲,乐校冬,王红平,等,2017.基于 WorldView-02 高分影像的 BP 和 RBF 神经网络遥感水深反演.地球科学,42(12):2345-2353.

水深,王晶晶和田庆久(2007)在海岸带浅海水深高光谱遥感反演方法研究中通过不同模型方法探讨反射率一阶微分和反射率与水深的关系,实验证明水深与水体反射率在近红外波段相关性最好.于瑞宏等(2009)对多光谱遥感数据应用多波段模型对水深数据与波段反射率及其组合建立对应的关系,最终确定了干旱区浅水湖泊的水深反演模型.Lyzenga(1978)在经典的辐射传输双流模型的基础上,推出水体反射比与水深之间的关系式.上述研究虽然能建立水深与反射率的关系,但是由于遥感水深反演是一个非线性过程,影响因素很多,这些方法很难达到高精度的要求.而且线性反演方法对研究区域要求比较高,水深的一般探测精度在 30 m 以内,水体较浑浊时则只有 10~20 m(黄文骞等,2013).

为了提高反演精度,很多学者开始将神经网络应用在水深反演上,建立水深与反射率的非线性关系.神经网络是在对人类大脑神经系统及功能模仿的基础上建立的人工智能(冯杭建等,2016).Antil and Coulibaly(2004)利用神经网络捕捉水深波动的复杂变化,分析输入延迟神经网络、递归神经网络、RBF 这 3 种网络建立水深波动模型的效果,最终得出结论递归神经网络更适合水深波动预测.邓正栋等(2013)分别建立了 BP(Back Propagation)和 RBF(Radial Basis Function)的水深反演模型,并与其他单波段、多波段模型进行比较,得到 RBF 模型的反演精度最高的结论.朱玉等(2013)提出基于混沌免疫算法优化 RBF.遥感水深反演的方法比较多,各个方法的精度受很多条件的影响(Poupardin *et al.*, 2015).为了选择最佳的神经网络,需要对比不同的方法和不同的参数对反演精度的影响进行研究分析,而这些在以前的文献中很少论述.本文选择地形较复杂的美济礁海域,对 WorldView-02 高分影像数据建立 BP 和 RBF 神经网络模型,为了提高反演的精度,用控制变量法改变 BP 网络的参数,使其训练的相关系数达到最大.并将训练完成的 BP 和 RBF 网络从不同角度分析两种神经网络在水深反演的优缺点,确定最优的水深反演模型.

## 1 研究区与数据

研究区美济礁是一个椭圆形的珊瑚礁,由潟湖、礁坪、裸沙洲、灌草丛被沙洲、沙洲组成,总面积大约 46 km<sup>2</sup>,是南沙最大的环礁,位于中国南海的中东部海域,地处 9°52'N~9°56'N, 115°29'E~115°35'E.



图 1 美济礁遥感影像

Fig.1 Satellite imagery in Mischief Reef

美济礁位于热带地区,年降水量丰富,符合水产养殖和鱼苗育种的环境要求,为当地经济发展提供条件,而且政府一直致力于美济岛的建设,因此对其水深的研究是很有必要的.美济礁海域地形复杂、水深波动较大,传统的水深测量方法有一定的困难.而神经网络方法反演水深对研究区域的要求低,可以对该区域完成水深反演.

高分辨率遥感影像具有丰富的空间信息(高伟等,2010),遥感数据采用 WorldView-02 传感器在 2011 年 3 月 18 日采集的高分辨率图像,如图 1 所示.包含 8 个波段,分别是 Coastal(400~450 nm)、Blue(450~510 nm)、Green(510~580 nm)、Yellow(585~625 nm)、Red(630~690 nm)、Red edge(705~745 nm)、NIR-1(770~895 nm)、NIR-2(860~1040 nm),成像时间是美济礁的旱季,不受雨水的干扰.照片拍摄是在中午 11:07:30,太阳直射天空、云层比较少,图像的质量不受外界环境影响.图像分辨率为 2 m,图像清晰,边界分明,图像的质量比较好.

水深数据是现场测量的水深数据 11 360 个,精度为 12 cm,水深范围 0~25 m,其中 0~10 m、20~25 m 的水深数据比较多,10~20 m 水深数据相对较少.本研究中根据现场测量水深数据的定位坐标将数据点匹配到 WorldView-02 遥感影像上,随机选取 1 226 个均匀分布的样本点,其中,1 000 个样本点作为训练数据,226 个作为测试数据.

## 2 遥感数据处理

### 2.1 辐射定标

为了获得图像的反射率值,需将无量纲的 DN

表 1 辐射定标参数

Table 1 Radiometric calibration parameters

Band	$absCalFactor_{Band}$	$\Delta\lambda_{Band}$
Coastal	$9.295\ 654 \times 10^{-3}$	$4.730\ 000 \times 10^{-2}$
Blue	$1.783\ 568 \times 10^{-2}$	$5.430\ 000 \times 10^{-2}$
Green	$1.364\ 197 \times 10^{-2}$	$6.300\ 000 \times 10^{-2}$
Yellow	$6.810\ 718 \times 10^{-3}$	$3.740\ 000 \times 10^{-2}$
Red	$1.851\ 735 \times 10^{-2}$	$5.740\ 000 \times 10^{-2}$
Red Edge	$6.063\ 145 \times 10^{-3}$	$3.930\ 000 \times 10^{-2}$
NIR-1	$2.050\ 828 \times 10^{-2}$	$9.890\ 000 \times 10^{-2}$
VNIR-2	$9.042\ 234 \times 10^{-3}$	$9.960\ 000 \times 10^{-2}$




图 2 大气校正前光谱曲线

Fig.2 Spectral curve before atmospheric correction




图 3 大气校正后光谱曲线

Fig.3 Spectral curve after atmospheric correction

值通过辐射定标转换为辐亮度值,再将辐亮度值通过大气校正转换为反射率值(López-Serrano *et al.*, 2016).因为 WorldView-02 遥感影像的头文件中不包含增益和偏移值,所以不能用传统的方法进行辐射定标.使用公式 1 将 DN 值转换为辐亮度值.

$$L_{\lambda_{Pixel, Band}} = \frac{absFactor_{Band} * q_{Pixel, Band}}{\Delta\lambda_{Band}}, \quad (1)$$

其中: $absCalFactor_{Band}$ 是绝对亮度定标因子( $W \cdot m^{-2} \cdot sr^{-1} \cdot count^{-1}$ ); $q_{Pixel, Band}$ 是辐射纠正过的图像像元值(counts); $\Delta\lambda_{Band}$ 有效波宽( $\mu m$ ),这些数据可从

遥感图像的头文件中读取,如表 1 所示. $L_{\lambda_{Pixel, Band}}$ 为大气层顶的波段光谱辐亮度( $W \cdot m^{-2} \cdot sr^{-1} \cdot \mu m^{-1}$ ).通过波段计算对美济礁图像的 8 个波段分别进行辐射定标,辐射定标后图像像素值为辐亮度值,为大气校正提供数据源.

## 2.2 大气校正

大气对不同波长的衰减作用是不同的,导致大气的谱发生变化,大气校正可以消除大气的影,使图像的谱曲线接近真实曲线.将辐射定标后的辐亮度图像经过 ENVI 软件的 FLAASH 模块大气校正(于亚凤等,2015),可得到反射率图像(韩晓庆等,2012).由于 WorldView-02 缺少短波红外,不能用  $K-T$  模型反演气溶胶,所以在大气校正时气溶胶反演选 NONE,气溶胶模型选 Marine.如图 2 和图 3 所示为大气校正前后水体的谱曲线图,图 3 纵坐标是地表反射率.因为反射率值为小数不利于存储,所以在 FLAASH 大气校正时缩放因子取 100.由于水体在蓝绿波段有较强反射,且反射率随着波长增加反射率降低,而大气校正后的谱曲线图在蓝绿波段反射率较高,且曲线随着波长增加呈下降趋势,相较大气校正前谱曲线图更符合水体的反射率变化情况,因此,大气校正基本消除了大气散射和吸收的影响.

## 3 神经网络水深反演

### 3.1 相关性分析

实测水深值和遥感影像数据各波段反射率的相关性会影响神经网络模型的建立.表 2 所示为水深数据与遥感影像 8 个波段的相关系数.其中,相关系数为负数表示一个变量的增加可能引起另一个变量的减少,相关系数的绝对值越接近 1 表明水深值和反射率值相关性越好.

根据表 2 可知,Coastal 波段和 Blue 波段的相关系数分别是  $-0.375$ 、 $-0.365$ ,绝对值小于其他 6 个波段相关系数的绝对值,Coastal 波段和 Blue 波

表 2 水深值与波段反射率值的相关系数

Table 2 The correlation coefficient between water depth and band reflectance

波段	Coastal	Blue	Green	Yellow
相关系数	$-0.375$	$-0.365$	$-0.439$	$-0.470$
波段	Red	Red Edge	NIR-1	NIR-2
相关系数	$-0.474$	$-0.467$	$-0.471$	$-0.469$




图 4 BP 神经网络模型  
Fig.4 BP neural network model

表 3 BP 网络训练参数

Table 3 BP training parameters

隐含层个数	隐含层函数	输出层函数	R
16	tansig	logsig	0.997 05
17	tansig	purelin	0.996 65
17	tansig	logsig	0.997 06
17	logsig	logsig	0.996 73
18	tansig	logsig	0.996 85

段与水深的相关性比其他 6 个波段与水深的相关性差,但是它们的水体衰减系数很小,水体穿透性大,很适合用于水深反演,所以本实验中选用遥感影像的 8 个波段.

### 3.2 BP 神经网络

BP 神经网络是由输入层、隐含层、输出层组成的一种前馈神经网络.层与层之间通过权值连接,每层都由神经元构成,学习过程通过信号在各个节点间传播,当信号正向传播时,信号从输入层经隐含层的逐层计算传递到输出层,每层的神经元只能影响下一层神经元;当信号反向传播时,误差作为信号从输出层反向经隐含层的逐层计算,然后传播到输入层,传播过程中逐次调整网络结构的权值和阈值,使误差达到最小(Ma and Liu, 2016).每个神经元又有不同的激励函数.BP 网络的激励函数一般采用 sigmoid 函数(刘明堂等, 2015),其函数表达式如下:

$$f = \frac{1 - e^{-x}}{1 + e^{-x}}, \tag{2}$$

式中: $x$  是输入向量; $f$  是输出向量.如图 4 所示是

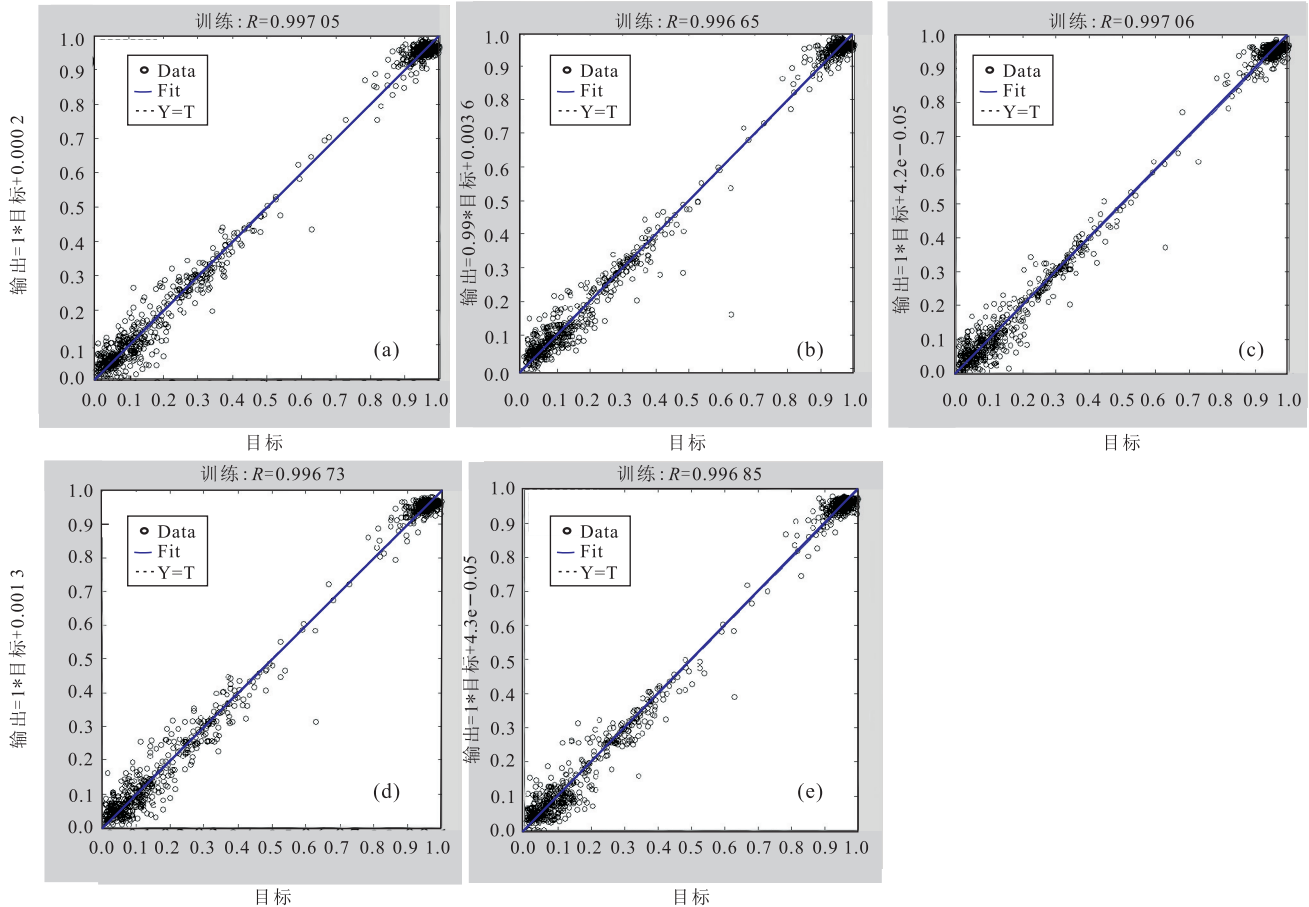


图 5 BP 网络训练回归图

Fig.5 BP training network regression figure

a.16, tansig, logsig; b.17, tansig, purelin; c.17, tansig, logsig; d.17, logsig, logsig; e.18, tansig, logsig



BP 神经网络模型, band1, band2, ..., band8 的反射率数据是输入层的输入向量, 实测水深是目标向量; 第 2 层是隐含层, 水深是输出层的输出向量; 输入层与隐含层、隐含层与输出层之间分别通过权值  $W_{ij}$  与  $W_{jk}$  连接。在选取的 1 226 个样本点中, 1 000 个用来训练网络, 226 个用来测试网络。为了加快训练网络的收敛性, 对提取的数据进行归一化处理。神经网络反演水深包括 2 个过程: (1) 在网络训练的过程中, 根据训练样本, 建立神经网络模型。输入向量经过模型的函数变换为输出向量即输出水深, 并输出网络训练的目标向量与输出向量的回归分析图, 如图 5 所示; (2) 在网络验证的过程中, 根据测试样本的实测水深和建立的网络模型预测测试样本点的水深。

输入层的输入向量选择遥感图像 8 个波段的反射率数据, 其中, Coastal 波段范围为 400~450 nm, 可用于叶绿素研究和深海探测研究; Blue 波段范围为 450~510 nm, 水体的穿透性最好, 水体衰减系数最小, 可用于判断水底地形、水深, 是水深反演的主要波段; Green 波段范围为 510~580 nm, 对水体、叶绿素有较强反射, 穿透性好, 可用于判断水深、识别绿色植物和判断植物生长状况, 对水深反演有很大影响; Yellow 波段范围为 585~625 nm, 可用于植被应用; Red 波段范围为 640~690 nm, 对植物强吸收, 可探测植物叶绿素吸收率进行植物分类; Red edge 波段范围为 705~745 nm, 可用于分析植物健康状况; NIR-1 和 NIR-2 波段范围分别为 770~895 nm 和 860~1 040 nm, 反射率较低, 对水深最为敏感, 水体强吸收, 可用于判断水深。

隐含层和激励函数的确定对 BP 网络的性能有很大影响。运用控制变量法分别改变隐含层神经元个数、隐含层函数、输出层函数这几个变量进行实验, 训练过程如表 3 所示。图 5a~5e 分别表示隐含层个数、隐含层函数、输出层函数按照表 3 变化时训练输出的结果。这 5 个图表示在训练 BP 网络时, 实测水深与训练输出水深的回归分析图, 随着训练次数的增加, 误差逐渐减小。图的横坐标表示经归一化后的实测水深, 纵坐标表示归一化后的输出水深,  $R$  表示实测水深与输出水深的相关性。 $R$  值越大, 实测水深与输出水深的相关性越好, 网络训练的效果越好。从结果可知  $R$  的大小受隐含层神经元个数、隐含层函数、输出层函数影响, 且当隐含层个数为 17, 隐含层函数为 tansig, 输出层函数为 logsig 时, 训练的  $R$  最大, 图上大多数的样本点都集中在对角线上, 实测水深与输出水深的拟合度最好, BP 网络性能最佳。

BP 神经网络有 3 层, 经过预处理后的遥感图像的 8 个波段的反射率作为输入层神经元。隐含层的神经元个数为 17, 输出层神经元为水深值。隐含层神经元函数为 tansig, 输出层函数为 logsig, 训练函数为 trainlm, 训练次数为 1 000, 训练精度为 0.001, 学习速率为 0.01。根据这些参数建立 BP 神经网络模型反演测试点的水深生成水深等值线图如图 6 所示。

### 3.3 RBF 神经网络

径向基(RBF)神经网络是由 Moody 和 Darken 提出的一种前向神经网络。它和 BP 神经网络一样也包含三个网络层, 但是一个 RBF 网络只有一层隐含层, 而一个 BP 网络可以有一层或者多层隐含层, 其隐含层函数一般是非线性的, 输出层函数是线性的。RBF 网络首先将原始的非线性可分的特征空间变换到另一线性特征空间, 通过合理选择变换函数使在新特征空间中问题线性可分, 然后用一个线性单元来表示原始关系。

RBF 网络的学习过程分为 3 个阶段: 第 1 阶段, 根据输入样本确定 RBF 的中心, 求解网络的宽度; 第 2 阶段, 确定神经元个数和作用函数; 第 3 阶段, 根据各样本确定输出层的权值和阈值, 同时校正隐含层和输出层参数, 以提高网络精度。RBF 网络的作用函数是局部逼近的高斯函数, 当网络的一个或多个可调参数变化时, 只会影响少数几个网络输出。这样对于网络的每次输入, 只需要调整少量的权值和阈值, 所以 RBF 网络的学习速度很快。而 BP 网络的作用函数是全局逼近的 sigmoid 函数, 网络的可调参数对任何输出都有影响, 每次输入样本都要调整相应的权值, 学习速度很慢。

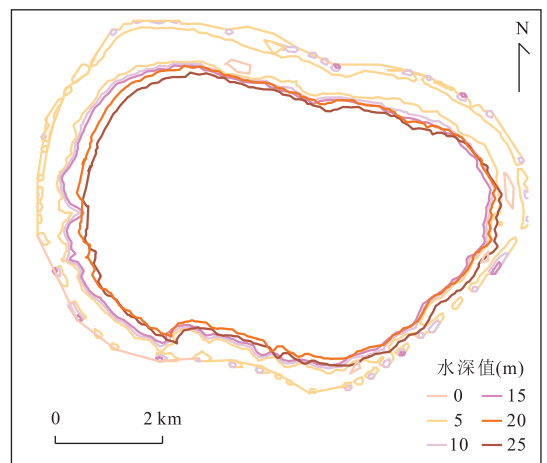


图 6 BP 反演结果水深等值线

Fig.6 The contours of water depth inversion based on BP




图 7 RBF 神经网络模型

Fig.7 RBF neural network model

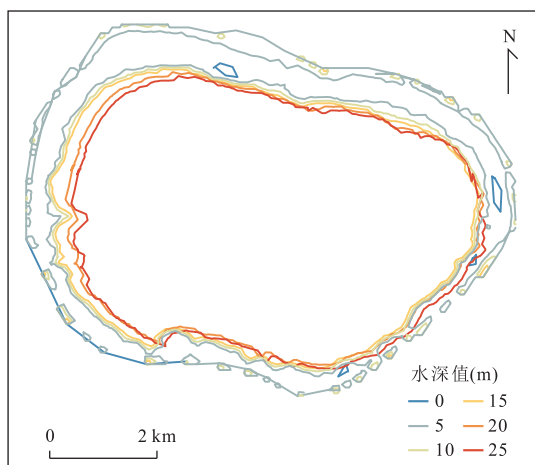


图 8 RBF 反演结果水深等值线

Fig.8 The contours of water depth inversion based on RBF

RBF 网络是一个黑箱结构,网络间通过函数的变换实现线性或非线形映射.输入层到隐含层通过高斯函数实现  $x \rightarrow f_i(x)$  的非线形映射,这种变换避免了 BP 网络容易陷入局部极小值的缺点.RBF 网络隐含层第  $i$  个节点的值可由公式 3 表示(高国栋等,2011).

$$f_i(x) = \exp\left[-\frac{(x - c_i)^T(x - c_i)}{2\sigma_i^2}\right], \quad (3)$$

式中: $x$  是输入向量; $f_i(x)$  是隐含层第  $i$  个节点的值;高斯函数中的 2 个参数:一个是均值  $c_i$ ,一个是标准方差常数  $\delta_i$ ,均值可以称作为中心向量.如果一个 RBF 网络的中心点、宽度以及权值确定了,这个神经网络就相应确定了.其中心点的选择影响网络的逼近能力,中心点选择太少会影响网络的性能,选择太多则会使网络的计算量增加,网络建立耗费的时间增加.

隐含层到输出层通过 purelin 函数实现  $f_i(x) \rightarrow y_k$  的线性映射,如公式 4 所示:

$$y_k = \sum_{i=1}^q \omega_{kj} f_i(x) - \theta_k, \quad (4)$$

式中: $y_k$  是输出层  $k$  个向量值; $q$  是隐层节点数; $\omega_{kj}$  是隐含层到输出层的加权; $\theta_k$  是输出层的阈值.对于每个训练样本,它只需要对少量的权值和阈值进行修正,然后通过自组织、自学习改变网络的结构,使网络达到最优化.

如图 7 所示是 RBF 网络模型,输入层输入向量是遥感图像的 8 个波段的反射率数据,目标向量是实测水深;隐含层函数是具有局部作用的高斯函数;输出层是输出水深值.输入层的各个反射率数据作为输入信号经过高斯函数的非线形变换实现  $x \rightarrow f_i(x)$  到达隐含层,经过 purelin 函数的线性变换实现  $f_i(x) \rightarrow y_k$  到达输出层,以水深的方式输出.根据以上参数建立 RBF 水深反演网络模型.模型用于反演测试样本点的水深后生成等值线图如图 8 所示.

## 4 精度评价与分析

在网络结构上,BP 网络需要设置大量的参数,为了获得最佳的网络模型,需要用试错法不断改变隐层神经元个数、隐层函数、输出函数,耗费时间.而 RBF 网络具有自学习、自组织能力,可以通过一些样本自学习得到最佳的训练网络,不需要太多人为干预.在样本选择上,因为 BP 网络隐层函数是全局作用的 sigmoid 函数,因此对训练样本的要求比较高,需要样本能包括事物的全部或大部分特征,而且对一些误差大的样本没有抗干扰能力.RBF 网络隐层函数是局部作用的高斯函数,对样本的要求没有那么高.

模型建立好后将经过归一化的 226 个测试样本分别输入训练好的网络,反演得到预测水深后进行反归一化处理,将反演结果与提取的实测水深比较,如图 9 和图 10 所示.从图 9 和图 10 中可以看出 BP 和 RBF 网络的拟合效果都比较好,预测的水深和实际水深基本相等,2 种模型在 15~25 m 水深范围内反演精度较高,0~15 m 水深范围内反演精度较低.相比 RBF 神经网络,BP 网络的波动性较大,尤其是在 5~15 m 水深范围内,反演效果并不理想,存在很大的误差.RBF 网络的稳定性比较强,抗干扰能力强,除了 0~5 m 水深范围内存在误差,其他水深范围保持高拟合,且数据分布均匀,更适合水深反演.

为了使反演结果更加清晰、精确,本文根据一些衡量标准决定系数( $R^2$ )、平均决定误差(MAE)、均方根误差(RMSE)、时间( $t$ )进行精度评价(周萍等,2015).




图 9 BP 水深反演

Fig.9 Water depth inversion based on BP




图 10 RBF 水深反演

Fig.10 Water depth inversion based on RBF

$$R^2 = \frac{\sum (y_i - \bar{y})^2 - \sum (y_i - y_j)^2}{\sum (y_i - \bar{y})^2}, \quad (5)$$

$$MAE = \frac{1}{n} \sum |y_i - y_j|, \quad (6)$$

$$RSME = \sqrt{\frac{\sum (y_i - y_j)^2}{n}}, \quad (7)$$

其中:  $y_i$  为实测水深值;  $y_j$  为预测水深值;  $\bar{y}$  为实测水深的平均值;  $n$  为测试的样本数目。决定系数  $R^2$  越大, 表示实际水深和预测水深相关性越大, 反演效果越好。MAE 越小, 表示实际水深与预测水深误差的绝对值越小, 反演效果越好。RMSE 越小, 表示水深预测误差的波动越小, 反演结果越好。时间  $t$  越小, 表示模型建立所用的时间越短。BP 和 RBF 模型反演结果如表 4 所示。表 4 分析可知, BP、RBF 模型的决定系数  $R^2$  虽然都很大, 达到了 0.9 以上, 但是 RBF 的  $R^2$  达到了 0.995, 实际水深和预测水深的关联性更好, 且 MAE 和 RMSE 的值小于 BP 模型, 所以 RBF 神经网络在水深反演的效果更好, 误差远小于 BP 模型。RBF 模型建立需要的时间也比较短,

表 4 BP 与 RBF 网络模型

Table 4 BP and RBF neural network model

网络模型	$R^2$	MAE(m)	RMSE(m)	$t$ (s)
BP	0.955 6	1.149 3	1.832 1	21
RBF	0.995 0	0.406 7	0.892 2	9

学习速度更快。

RBF 水深反演效果优于 BP 神经网络是由两种网络的结构特点造成的。虽然两种网络都可以任一精度逼近任一连续函数, 但是 BP 网络的作用函数是具有全局作用的 sigmoid 函数, 而 RBF 网络的作用函数是局部作用的高斯函数。在本研究中, 用于水深反演的数据是随机选取的, 且样本数据比较离散, 存在很多噪声, 因此在 BP 网络训练时容易陷入局部最小, 而 RBF 网络可以获得比较好的反演效果。

## 5 结论

用于水深反演的反射率与水深值之间存在复杂的非线性关系, 传统的单波段、多波段水深反演模型不能很好地反映这种关系。神经网络作为一种高精度的非线性映射, 通过对输入反射率经隐含层的多次线性和非线性变换, 得到的水深值与实际值误差很小 (Ceyhun and Yalcin, 2010)。本文以 WorldView-02 影像为数据源使用 BP 和 RBF 两种神经网络方法对美济礁进行遥感实验研究。为了提高网络训练的精度, BP 网络模型设置神经元个数为 17, 作用函数分别为具有全局作用的 sigmoid 函数: tan-sig, logsig 函数; RBF 网络模型设置作用函数为局部作用的高斯函数。用训练好的神经网络模型反演测试点的水深, 反演结果表明: 相比 BP 网络, RBF 网络的决定系数提高了 0.039 4, 达到了 0.995; 平均决定误差、均方根误差分别下降了 0.742 6、0.939 9; 时间缩短了 12 s。RBF 网络反演水深的精度高, 反演速度快, 网络收敛性好。

## References

- Ceyhun, Ö., Yalcin, A., 2010. Remote Sensing of Water Depths in Shallow Waters via Artificial Neural Networks. *Estuarine Coastal and Shelf Science*, 89(1): 89–96.
- Ancil, F., Coulibaly, P., 2004. Wavelet Analysis of the Inter-annual Variability in Southern Québec Streamflow. *Journal of Climate*, 17(1): 163–173. doi: 10.1175/1520-0442(2004)017<0163:WAOTIV>2.0.CO;2

- Dang, F. X., Ding, Q., 2003. The Use of Multi-Band Satellite Data to Study Shallow Water Depth Inversion. *Marine Science Bulletin*, 22(3): 55–60 (in Chinese).
- Deng, Z. D., Ye, X., Guan, H. J., et al., 2013. Remote Sensing of Water Depth Based on RBF Neural Network. *Journal of PLA University of Science and Technology (Natural Science Edition)*, 14(1): 101–106 (in Chinese with English abstract).
- Feng, H. J., Zhou, A. G., Yu, J. J., et al., 2016. A Comparative Study on Plum-Rain Triggered Landslide Susceptibility Assessment Models in West Zhejiang Province. *Earth Science*, 41(3): 403–415 (in Chinese with English abstract).
- Gao, G. D., Zhang, W. X., Mu, G. Y., 2011. A Comparative Study on RBF Network and BP Network in the Model of Salinity. *Marine Science Bulletin*, 30(1): 12–15 (in Chinese with English abstract).
- Gao, W., Liu, X. G., Peng, P., Chen, Q. H., 2010. An Improved Method of High-Resolution Remote Sense Image Segmentation. *Earth Science*, 35(3): 421–425 (in Chinese with English abstract).
- Han, X. Q., Su, Y., Li, J., et al., 2012. Atmospheric Correction and Verification of the SPOT Remote Sensing Image in Coastal Zones. *Geographical Research*, 31(11): 2007–2016 (in Chinese with English abstract).
- Huang, W. Q., Wu, D., Yang, Y., et al., 2003. Multi-Spectral Remote Sensing Water Depth Retrieval Technique in Shallow Sea. *Ocean Technology*, 32(2): 43–46 (in Chinese with English abstract).
- Liu, M. T., Zhang, C. C., Tian, Z. Z., et al., 2016. RBF Neural Networks Based-Study on Data Fusion for Measurement of Sediment Concentration of Yellow River. *Water Resources and Hydropower Engineering*, 46(1): 126–130 (in Chinese with English abstract).
- López-Serrano, P. M., Corral-Rivas, J. J., et al., 2016. Evaluation of Radiometric and Atmospheric Correction Algorithms for Aboveground Forest Biomass Estimation Using Landsat 5 TM Data. *Remote Sensing*, 8(5): 369. doi: 10.3390/rs8050369
- Lyzenga, D. R., 1978. Passive Remote Sensing Techniques for Mapping Water Depth and Bottom Features. *Applied Optics*, 17(3): 379–383. doi: 10.1364/AO.17.000379
- Ma, H. Z., Liu, S. M., 2016. The Potential Evaluation of Multi-source Remote Sensing Data for Extracting Soil Moisture Based on the Method of BP Neural Network. *Canadian Journal of Remote Sensing*, 42(2): 117–124.
- Poupardin, A., Idier, D., De Michele, M., et al., 2015. Water Depth Inversion from a Single SPOT-5 Dataset. *IEEE Transactions on Geoscience and Remote Sensing*, 54(4): 2329–2342. doi: 10.1109/TGRS.2015.2499379
- Su, H. B., Liu, H. X., Wu, Q. S., 2015. Prediction of Water Depth From Multispectral Satellite Imagery—The Regression Kriging Alternative. *IEEE Geoscience and Remote Sensing Letters*, 12(12): 2511–2515. doi: 10.1109/LGRS.2015.2489678
- Wang, J. J., Tian, Q. J., 2007. Study on Shallow Coastal Water Depth Derived Method Based on Hyperspectral Remote Sensing. *Scientia Geographica Sinica*, 27(6): 843–848 (in Chinese with English abstract).
- Wang, Y. J., Zhang, P. Q., Dong, W. J., et al., 2007. Study on Remote Sensing of Water Depths Based on BP Artificial Neural Network. *Marine Science Bulletin*, 9(1): 26–35.
- Yu, R. H., Xu, Y. P., Liu, T. X., et al., 2009. Reversing Water Depth in Shallow Lake of Arid Area Using Multi-Spectral Remote Sensing Information. *Advances in Water Science*, 20(1): 111–117 (in Chinese with English abstract).
- Yu, Y. F., Yang, J. Z., Chen, S. B., et al., 2015. Lithologic Classification from Remote Sensing Images Based on Spectral Index. *Earth Science*, 40(8): 1415–1419 (in Chinese with English abstract).
- Zhou, P., Li, N., Huo, H. Y., 2015. The Quality Assessment of Hymap Simulation Spaceborne Hyperspectral Data. *Earth Science*, 40(8): 1310–1318 (in Chinese with English abstract).
- Zhu, Y., Zhao, Q., Zhou, X. D., 2013. Remote Sensing Water Depth Inversion Based on Chaotic Immune Optimization RBF Network. *Computer Engineering*, 39(5): 187–191 (in Chinese with English abstract).

## 附中中文参考文献

- 党福星, 丁谦, 2003. 利用多波段卫星数据进行浅海水深反演方法研究. *海洋通报*, 22(3): 55–60.
- 邓正栋, 叶欣, 关洪军, 等, 2013. 基于 RBF 神经网络的水深遥感研究. *解放军理工大学学报: 自然科学版*, 14(1): 101–106.
- 冯杭建, 周爱国, 俞建君, 等, 2016. 浙西梅雨滑坡易发性评价模型对比. *地球科学*, 41(3): 403–415.
- 高国栋, 张文孝, 慕光宇, 2011. RBF 网络和 BP 网络在海水盐度建模中的比较研究. *海洋通报*, 30(1): 12–15.
- 高伟, 刘修国, 彭攀, 等, 2010. 一种改进的高分辨率遥感影像分割方法. *地球科学*, 35(3): 421–425.
- 韩晓庆, 苏艺, 李静, 等, 2012. 海岸带地区 SPOT 卫星影像大气校正方法比较及精度验证. *地理研究*, 31(11): 2007–2016.
- 黄文骞, 吴迪, 杨杨, 等, 2013. 浅海多光谱遥感水深反演技术. *海洋技术*, 32(2): 43–46.



刘明堂,张成才,田壮壮,等,2015.基于 RBF 神经网络的黄河含沙量测量数据融合研究.水利水电技术,46(1):126-130.

王晶晶,田庆久,2007.海岸带浅海水深高光谱遥感反演方法研究.地理科学,27(6):843-848.

于瑞宏,许有鹏,刘廷玺,等,2009.应用多光谱遥感信息反演干旱区浅水湖泊水深.水科学进展,20(1):111-117.

于亚凤,杨金中,陈圣波,等,2015.基于光谱指数的遥感影像岩性分类.地球科学,40(8):1415-1419.

周萍,李娜,霍红元,2015.基于 Hymap 模拟的星载高光谱数据质量评价.地球科学,40(8):1310-1318.

朱玉,赵卿,周兴东,2013.基于混沌免疫优化 RBF 网络的遥感水深反演.计算机工程,39(5):187-191.

\*\*\*\*\*

## 《地球科学》编辑部入选中国高校科技期刊优秀团队

中国高校科技期刊研究会第 21 次年会暨建会 30 周年纪念会、优秀团队和个人遴选结果发布会于近日在北京会议中心隆重举行.中国地质大学(武汉)《地球科学》编辑部入选中国高校科技期刊优秀团队,地球科学在线网站获得第四届中国高校科技期刊优秀网站,名誉主编王亨君同志获得从事高校科技期刊编辑出版工作 30 年荣誉证书,姚戈同志入选中国高校科技期刊优秀编辑,肖骏同志入选中国高校科技期刊优秀青年编辑.

有来自全国高校科技期刊编辑出版单位的 300 余位代表出席了年会.