

文章编号:1007-4619(2002)06-0451-05

# 基于神经网络方法的极化雷达地表参数反演

杨 虎,郭华东,王长林,李新武,岳焕印

(中国科学院 遥感应用研究所遥感信息科学重点实验室,北京 100101)

**摘要:** 神经网络(Artificial Neural Network)是一个由独立处理单元以一定拓扑结构高度连接而成的并行分布式信息处理结构,适于解决各种非线性问题。积分方程(Integrated Equation Model)单散射模型可模拟各种地表参数条件下裸露地表后向散射系数。以 IEM 为基础生成训练数据,用 L 波段和 C 波段 SIR-C HH, VV 极化单散射后向散射系数数据为神经网络输入,通过后向反馈(BP)神经网络模型可同时反演得到裸露地表条件下地表介电常数、地表相关长度和均方根高度等地表参数。

**关键词:** 极化雷达;积分方程模型;BP 神经网络;地表参数反演

**中图分类号:** TP722.6 **文献标识码:** A

## 1 引言

地表参数如地表土壤水分和表面粗糙度信息在地学应用中有十分重要的作用。表面粗糙度是反映地表蚀变情况的一个重要地球物理参数<sup>[1]</sup>。土壤水分是水文模型中重要参量,不同尺度的准确土壤水分测量能大大提高模型精度。同时,土壤水分是作物长势监测和估产的主要参数,准确、快速、大范围的土壤水分测量是作物生长状态监测和估产模型所必需的。但是这些地表参数在传统地表测量方法很难在大范围、高效率 and 全过程进行常规测量得到的。而可见光、近红外等已经存在的卫星传感器由于受云盖及太阳照射条件的限制,使对土壤水分的遥感测量不能达到足够的敏感程度,对关键的科学应用问题而言也缺乏要求的时空分辨率。

在微波波段,土壤水分和介电常数密切相关。最近微波遥感研究的发展显示了定量估算裸土和矮小植被下土壤水分的潜力,提高发展了微波遥感反演这些参数的灵活性<sup>[2]</sup>。在主动微波遥感领域,合成孔径雷达(SAR)已成为国际对地观测领域最重要的前沿技术之一。同时成像的多波段极化 SAR 系统可以获得不同波段雷达的回波响应及线性极化状态下同极化与交叉极化信息,可更准确的探测目标特征。利用主动微波雷达反演土壤水分能大大提高

反演的准确性和可靠性。并且不受天气条件的限制。目前,应用极化雷达同时反演土壤水分和粗糙度面临的主要问题是如何在模型中分离介电常数和粗糙度的影响及在不同植被覆盖条件下建立模型反演地表参数。

地表参数(介电常数、粗糙度)与雷达后向散射系数之间是非常复杂的非线性关系,一些从实验数据得到的半经验模型并不能充分表达这种非线性关系。神经网络(NN)被广泛应用于解决各种非线性问题,以多波段极化雷达后向散射系数数据作为神经网络输入可解决主动微波遥感中多地表参数反演问题。应用神经网络解决反演问题的关键是合适的网络模型、训练模式的选取及大量训练数据要求。本文以积分方程模型 IEM (Integrated Equation Model)为基础生成训练数据,使训练数据中后向散射系数与地表参数间有明确的物理关系。最后通过 L 波段和 C 波段水平(HH)和垂直(VV)线极化后向散射系数作为神经网络输入,同时反演得到地表介电常数、表面粗糙度信息,取得了较好的效果。

## 2 极化雷达地表参数反演研究现状

近年来,通过多模式(多波段、多极化、可变入射角)地表散射计数据分析雷达后向散射系数与频率、

收稿日期:2002-05-01;修订日期:2002-06-01

基金项目:国家自然科学基金重点项目(49989001),国家 863 计划项目(2001AA132040)及中国科学院知识创新工程项目(KZCX2-312)资助。

作者简介:杨虎(1976—),男,中国科学院遥感应用研究所博士研究生,研究方向为微波遥感。

极化、入射角及地表参数(介电常数、表面均方根高度 RMS height、相关长度 correlation length)间的相关关系,发展了一些用极化雷达同时反演介电常数和地表粗糙度(主要是地表均方根高度,没有考虑地表相关长度)的经验模型,实际应用中模型计算与地表实测数据吻合较好的有 Oh 模型、Dubois 模型和 Shi 模型。

### 2.1 Oh 模型

利用多波段、全极化地面散射计对不同粗糙度地表散射特性的多角度观测,Oh 等分别得到了后向散射系数同极化比和交叉极化比与介电常数及地表粗糙度的经验模型<sup>[3]</sup>:

$$q = \frac{\sigma_{HV}^{\circ}}{\sigma_{VV}^{\circ}} = 0.23 \sqrt{\Gamma_0} \cdot [1 - \exp(-ks)]$$

$$p = \frac{\sigma_{HH}^{\circ}}{\sigma_{VV}^{\circ}} = \left\{ 1 - \left( \frac{2\theta}{\pi} \right)^{1/3} \Gamma_0 \cdot \exp(-ks) \right\}^2$$

$$\Gamma_0 = \left| \frac{1 - \sqrt{\epsilon}}{1 + \sqrt{\epsilon}} \right|^2$$

上式中,  $k$  为自由空间波数,  $s$  为地表均方根高度。Oh 模型的特点是应用的地表粗糙范围宽,在归一化表面均方根高度为 0.1—6.0 和相关长度为 2.6—19.7 的表粗糙范围内模型预测值都能和实际观测值取得较为一致的结果。但 Oh 模型较多的依赖地面观测的经验参数,其普遍适用性需要得到进一步的验证。

### 2.2 Dubois 模型

通过分析地表散射特性的全极化散射计测量值,Dubois 等分别得到了两种同极化后向散射系数与地表介电常数和表征地表粗糙度的均方根高度  $s$  之间的经验关系<sup>[4]</sup>:

$$\sigma_{VV}^{\circ} = 10^{-2.35} \cdot \left( \frac{\cos^3 \theta}{\sin^3 \theta} \right) \cdot 10^{0.046 \cdot \epsilon_r \cdot \tan \theta} \cdot (ks \cdot \sin \theta)^{1.1} \cdot \lambda^{0.7}$$

$$\sigma_{HH}^{\circ} = 10^{-2.75} \cdot \left( \frac{\cos^{1.5} \theta}{\sin^5 \theta} \right) \cdot 10^{0.028 \cdot \epsilon_r \cdot \tan \theta} \cdot (ks \cdot \sin \theta)^{1.4} \cdot \lambda^{0.7}$$

在满足  $ks < 2.5$ , 雷达入射角大于  $30^\circ$ , 且体土壤含水量小于 35% 的情况下 Dubois 模型应用效果较好。在更为粗糙的地表条件下, Dubois 模型预测的 HH 极化后向散射系数较 VV 极化大,这与理论模型预测值及 SAR 观测值都相反。在  $ks > 2.5$  粗糙地表条件下, Dubois 模型不再适用。

### 2.3 Shi 模型

依据 IEM, 通过数字模拟不同表面粗糙度和土

壤体含水量条件下表面后向散射特性,施建成等建立了 L 波段不同极化组合后向散射系数与介电常数和地表粗糙度功率谱之间的相关关系<sup>[5]</sup>:

$$10 \log_{10} \left[ \frac{|\alpha_{pp}|^2}{\sigma_{pp}^{\circ}} \right] = a_{pp}(\theta) + b_{pp}(\theta) 10 \log_{10} \left[ \frac{1}{S_R} \right]$$

$$10 \log_{10} \left[ \frac{|\alpha_{VV}|^2 + |\alpha_{HH}|^2}{\sigma_{VV}^{\circ} + \sigma_{HH}^{\circ}} \right] = a_{VH}(\theta) + b_{VH}(\theta) 10 \log_{10} \left[ \frac{|\alpha_{VV}| + |\alpha_{HH}|}{\sqrt{\sigma_{VV}^{\circ} \sigma_{HH}^{\circ}}} \right]$$

其中  $\alpha_{pp}$  为 P 极化状态下的极化幅度,  $S_R$  为粗糙度谱,  $a, b$  均为与入射角有关的经验系数。由于模型中考虑了粗糙度谱对后向散射系数的影响,所以这一模型在实际应用中对地表介电常数的反演能取得较好的结果。

## 3 积分方程单散射模型

裸露地表的后向散射系数依赖于介电常数和表面粗糙度,后者一般是由一个自相关函数和表面高度的标准离差描述的。由于大多数地表的表面均方根坡度较小,且大多数条件下单散射将控制多散射,所以实际应用中用单散射积分方程 IEM 模型模拟裸露地表后向散射特性。

IEM 单散射模型由下式给出:

$$\sigma_{pp}^s(s) = \frac{k^2}{2} \exp(-2k_z^2 \sigma^2) \sum_{n=1}^{\infty} \sigma^{2n} |I_{pp}^n|^2 \frac{W^n(-2k_x, 0)}{n!}$$

其中,

$$I_{pp}^n = (2k_z)^n f_{pp} \exp(-\sigma^2 k_z^2) + \frac{k_z^2 [F_{pp}(-k_x, 0) + F_{pp}(k_x, 0)]}{2}$$

以上两式中,  $pp$  代表极化状态且

$$f_{VV} = \frac{2R_v}{\cos \theta}$$

$$f_{HH} = \frac{-2R_h}{\cos \theta}$$

$$F_{VV}(-k_x, 0) + F_{VV}(k_x, 0) = \frac{2 \sin^2 \theta (1 + R_v)^2}{\cos \theta}$$

$$\cdot \left[ \left( 1 - \frac{1}{\epsilon_r} \right) + \frac{\mu_r \epsilon_r - \sin^2 \theta - \epsilon_r \cos^2 \theta}{\epsilon_r^2 \cos^2 \theta} \right]$$

$$F_{HH}(-k_x, 0) + F_{HH}(k_x, 0) = -\frac{2 \sin^2 \theta (1 + R_h)^2}{\cos \theta}$$

$$\cdot \left[ \left( 1 - \frac{1}{\mu_r} \right) + \frac{\mu_r \epsilon_r - \sin^2 \theta - \mu_r \cos^2 \theta}{\mu_r^2 \cos^2 \theta} \right]$$

以上方程中,  $\theta$  为入射角,  $R_H$  和  $R_V$  为水平和垂直 Fresnel 反射系数;  $\epsilon_r$  和  $\mu_r$  是表面相对介电常数和磁导率;  $\sigma$  为表面高度标准离差;  $k$  为自由空间波数;

$k_z = k \cos(\theta_i)$ ;  $k_x = k \sin(\theta_i)$ ;  $W^n$  为已知表面相关函数第  $n$  项能量的傅里叶变换,可以写作:

$$W^n(k) = \int_0^\infty \rho^n(\xi) J_0(k\xi) \xi d\xi$$

$\rho$  表示相关公式;  $J_0$  是第 0 阶 Bessel 公式。

模型模拟与地表实测数据比较的研究结果表明,单散射 IEM 模型能够代表 L 波段和 C 波段极化雷达地表后向散射系数测量值<sup>[4]</sup>。本研究中,由于研究区地表条件大多为裸露地表,所以采用单散射 IEM 模型能模拟真实地表后向散射系数。

## 4 基于 IEM 模型的后向反馈(BP)神经网络反演模型

人工神经网络模型是人类神经系统一阶近似的数学模型,广泛用于解决各类非线性问题。它可以描述为一个由独立处理单元以一定拓扑结构高度连接而成的并行分布式信息处理结构。目前应用广泛的神经网络模型有自适应共振神经网络(ART),双向连接记忆神经网络(BAM),自组织图神经网络(SOM),多层感知器(MLC)后向反馈神经网络(BP)等。

神经网络用于解决地表参数反演时,地表参数与雷达观测值之间的映射关系可用下式表达:  $F(\Theta) \rightarrow Z$ ;  $\Theta$  为地表参数集,包括地表介电常数、表面均方根高度;  $Z$  为雷达测量数据集,包括不同频率、入射角及极化组合的后向散射系数数据。每一个神经网络训练模式包括  $N$  个雷达测量数据和  $M$  个地表参数数据。其中,雷达测量值中还包含 Gauss 分布的随机噪声。即  $Z$  为地表信息  $S(\Theta)$  与噪声  $n$  之和:  $Z = S(\Theta) + n$ 。

神经网络地表参数反演过程中,训练数据的选取十分重要。训练模式的确定应满足以下条件<sup>[7]</sup>: (1)训练数据的范围应包括所有感兴趣的典型地表参数范围;(2)训练模式中,后向散射系数随频率、极化、入射角等参数的变化趋势应与地面测量值一致;(3)选择相关性较小的数据作为训练模式中的输入。实际上,满足这样条件的训练数据不能由野外测量的点数据集中得到。而由于 IEM 模型可以模拟各种地表条件下后向散射特性,给定感兴趣的地表介电常数、RMS 高度、及相关长度的变化范围,神经网络训练数据可由本文第 3 部分给出的 IEM 单散射模型生成。选取适当的拓扑结构,通过训练成功的神经网络模型可由极化雷达数据中同时反演得到介电

常数、粗糙度等地表参数。

理论上,BP 网络能够模拟任何类型的函数映射关系,但在实际中应用于较为复杂的问题时,神经网络对训练数据的记忆功能要强于对函数关系的学习能力<sup>[8]</sup>。在进行全极化数据神经网络反演时,由于神经网络的记忆功能,即使网络训练成功,在实际反演中也会出现没有实际意义的值,如介电常数出现负值。为避免这一问题,必须选取多组训练数据集对网络进行训练。

下节介绍在新疆西昆仑阿克赛钦湖地区应用散射模型(IEM)-神经网络(NN)模型,用 SIR-C 多波段极化数据进行地表参数反演的研究工作。

## 5 IEM-NN 模型在阿克赛钦湖地区地表参数反演中的应用

### 5.1 数据描述与处理

航天飞机成像雷达 SIR-C/X-SAR 是美国宇航局(NASA)、德国空间署、意大利空间署联合进行的一次航天飞机极化雷达地面成像试验。SIR-C/X-SAR 系统搭载 NASA 的航天飞机于 1994 年 4 月和 10 月进行了两次各为 10 天的飞行试验。SIR-C 同时提供 L 波段和 C 波段的雷达全极化数据,这些极化数据能提取单像素的完整极化矩阵、几何结构的细节信息和目标的介电常数。

选取的阿克赛钦湖地区 SIR-C L 波段和 C 波段数据为 4 视全极化数据,地距分辨率为  $12.5\text{m} \times 12.5\text{m}$ 。首先对数据解压缩并计算得到后向散射系数。为消除多散射和雷达噪声的影响,用 Cloude 目标分解算法得到  $L_{HH}$ ,  $L_{VV}$ ,  $C_{HH}$ ,  $C_{VV}$  单散射后向散射系数数据<sup>[9]</sup>。对得到的数据进行斜-地距转换并进行 Gamma-MAP 滤波处理以减小雷达噪声。

### 5.2 BP 神经网络反演方法和结果

本研究中,应用 IEM-NN 反演方法进行地表参数反演分 4 个步骤进行:

(1)在敏感性分析的基础上选择待反演地表参数的范围。利用散射模型(IEM)进行参数敏感性分析,在确定的参数范围内,IEM 模型的模拟后向散射系数要与待反演地表参数有确定的对应关系,在对研究区地表条件分析的基础上初步选定地表参数范围,代入 IEM 模型中进行敏感性分析,最终确定的地表参数范围如表 1。

(2)用 IEM 模型产生训练数据。考虑到 BP 网络训练时间,本研究采用 500 个训练模式对,每一训练模式包括 L 波段和 C 波段 HH 和 VV 极化单散射后向散射系数及相应的地表参数(地表介电常数,表面均方根高度,相关长度)。在相应的地表参数范围内由 IEM 模型随机产生的后向散射系数中要加入高斯随机噪声,噪声水平由 SIR-C 系统参数确定。

(3)用后向反馈(BP)算法对网络进行训练,经过多次试验,反演中采用 4—16—16—3 的网络拓扑结构。以可变学习效率梯度下降函数对网络进行训练,训练叠代 1000 次。神经网络训练参数如表 2。

(4)用训练成功的网络进行地表参数反演。网络训练完成后,就可以在实际应用中进行地表参数反演。用训练成功的网络进行参数反演,得到研究区介电常数实部、相关长度、RMS 高度等地表参数

数据。

表 1 用于训练数据的裸露地表表面参数范围  
Table 1 Range of surface parameters for training neural network

	表面参数下界	表面参数上界
介电常数 $\epsilon$	1.5	4.0
RMS 高度 $K\delta$	0.02	0.9
相关长度 $KL$	1.2	4

表 2 BP 神经网络训练参数  
Table 2 Training parameters for BP NN

训练叠代次数	1000
训练动力 $mc$	0.9
学习效率 $lr$	0.05
训练误差 MSE	0.23
目标误差	0.001




图 1 阿克赛钦湖地区地表参数提取结果

Fig. 1 Surface geophysical parameters inverted from IEM-NN model

图 1 是反演得到的研究区地表参数图像,自左至右依次为介电常数、归一化相关长度和 RMS 高度。阿克赛钦湖为一退缩的高山盐湖,从反演结果来看,介电常数、均方根高度图像中噪声较大,噪声的影响掩盖了图像特征。相关长度图像与退缩的湖岸线特征较为吻合,在平坦湖岸和干涸河道相关长度较小;山区及湖岸四周的裸露地表相关长度较大,反演结果与地表实际状况基本符合。

为进一步验证反演结果精度,在研究区随机选取 80 个点,取其模型反演得到的介电常数实部、相关长度(KL)、RMS 高度(KS)值,代入 IEM 单散射模型计算 L 波段 C 波段 HH、VV 极化单散射后向散射系数。将计算出的理论值与对应点实际雷达测量值比较,分析其均方根误差(RMSE),L 和 C 波段 HH、VV 极化通道的 RMSE 分别为 2.5,2.4 和 1.7,2.0。结果表明用 IEM 模型计算的地表单散射后向散射

系数比实际雷达测量值平均高 6dB,且 C 波段反演误差较 L 波段小。

## 6 结论与讨论

应用极化雷达反演裸露地表参数已进行了许多研究工作,其主要问题是发展模型过程中缺乏后向散射系数测量值与相应的地表实测数据。由于缺乏合适的训练数据,目前的雷达后向散射系数——地表参数前向经验模型不具有普遍适用性。神经网络能有效解决各种非线性问题,应用神经网络反演地表参数的关键是合适的训练模式的选择、训练数据的选取及算法的实现。本文在典型的地表参数范围内(介电常数、表面粗糙度),以 IEM 单散射模型为基础生成 L 和 C 波段后向散射系数数据,以此作为 BP 神经网络的训练数据。在阿克赛钦湖研究区,选取

SIR-C L 和 C 波段全极化数据,用训练成功的神经网络模型反演得到了地表介电常数、粗糙度等地球物理参数。反演结果表明,以 IEM 模型为基础的神经网络模型不失为是一种行之有效的参数反演方法。

下一步的研究工作将进行神经网络地表参数反演模型在有植被覆盖地区的应用研究。

### 参 考 文 献 (References)

- [1] Evans D. L, Farr T G, Van Zyl J J. Estimates of Surface Roughness Derived from Synthetic Aperture Radar (SAR) Data [J]. *IEEE Trans Geosci and Remote Sensing*, 1992, **30**(2): 382—389
- [2] Zielinska K D Y I *et al.* Various Approaches for Soil Moisture estimates Using Remote Sensing [A]. IGARSS [C]. 2001.
- [3] Oh Y Sarabandi, K Ulaby F T. An Empirical Model and an Inversion Technique for Radar Scattering from Soil Surfaces [J]. *IEEE Trans. Geosci. and Remote Sensing*, 1992, **30**(2): 370—381.
- [4] Dubois P C, Van Zyl J J, Engman, T. Measuring Soil Moisture with Imaging Radars [J]. *IEEE Trans. Geosci. and Remote Sensing*, 1995, **33**.(4): 915—926.
- [5] Shi J C, Wang J, Hsu, A Y *et al.* Estimation of Bare Surface Soil Moisture and Surface Roughness Parameter Using L-band SAR Image Data [J]. *IEEE Trans. Geosci and Remote Sensing*, 1997, **35**(5): 1254—1265.
- [6] Fung A. K, Li Z Q, Chen K S. Backscattering from a Randomly Rough Dielectric Surface [J]. *IEEE Trans. Geosci. and Remote Sensing*, 1992, **30**(2): 356—369.
- [7] Dawson M S, Fung A K, Manry M T. Surface Parameter Retrieval Using Fast Learning Neural Networks [J]. *Remote Sensing Reviews*, 1993, **7**: 1—18.
- [8] Fung A K. *Microwave Scattering and Emission Models and Their Applications* [M]. Artech House, Boston, London, 1990.
- [9] Van Zyl J J. Application of Cloude's Target Decomposition Theorem to Polarimetric Imaging Radar Data [J]. *Radar Polarimetry*, 1992, **1748**: 184—191.

## Polarimetric SAR Surface Parameters Inversion Based on Neural Network

YANG Hu, GUO Hua-dong, WANG Chang-lin, LI Xing-wu, YUE Huan-yin

(LARSIS, Institute of Remote Sensing Applications, CAS, Beijing 100101, China)

**Abstract:** Surface parameters inversion by using Polarimetric SAR includes the inversion of the soil surface permeability, correlation length and RMS height. The retrieval of scattering parameters can be viewed as a mapping problem from the domain of measured signals to the range of surface/medium characteristics that quantify the observed medium. To date, parameter inversion has been based largely on empirical models. Empirical models have usually avoided the nonuniqueness problem by limiting the validity of the model to a single parameter and a narrow range. This limit on the range of validity requires that multiple empirical models be created—one model for each parameter. In this study, the Spaceborn Imaging Radar SIR-C data at L and C band was used to perform the inversion of bare surface parameters. A BP neural network based on IEM model was developed to carry out the inversion, and a test method was also developed. The combination of a scattering model (IEM) and NN makes it possible to perform inversion with higher accuracy and in real time. Backscattering coefficients computed from the model inverted surface parameters was proved to be good, compared with the real backscattering coefficients from radar image.

**Key words:** IEM model; polarimetric SAR; neural network; surface parameters inversion