

文章编号:1001-9014(2012)03-0283-06

DOI:10.3724/SP.J.1010.2012.00283

## 基于遗传 BP 神经网络的主被动遥感 协同反演土壤水分

余 凡<sup>1,2</sup>, 赵英时<sup>2</sup>, 李海涛<sup>1</sup>

(1. 中国测绘科学研究院 地理空间信息工程国家测绘局重点实验室,北京 100830;

2. 中国科学院研究生院 资源与环境学院,北京 100049)

**摘要:**提出了一种基于遗传神经网络算法的主被动遥感协同反演地表土壤水分的方法。首先,建立一个BP神经网络,并采用遗传算法对BP网络的节点权值进行了优化。然后分别将TM数据(TM3, TM4, TM6)、不同极化和极化比的(VV, VH, VH/VV)ASAR数据作为神经网络的输入,土壤水分含量作为网络的输出,用部分实测数据对网络进行训练并反演得到研究区土壤水分布图。最后,利用地面实测数据分别对遗传神经网络优化算法的有效性和主被动遥感协同反演的效果进行了验证,结果表明,新优化算法是有效可行的,且TM和ASAR协同反演的结果比两者单独反演的结果明显要好,体现了主被动遥感协同反演土壤水分的优势与潜力。

**关 键 词:** 主被动遥感; GA-BP 神经网络; 土壤水分; 反演

中图分类号:P237 文献标识码:A

### Soil moisture retrieval based on GA-BP neural networks algorithm

YU Fan<sup>1,2</sup>, ZHAO Ying-Shi<sup>2</sup>, LI Hai-Tao<sup>1</sup>

(1. Key Laboratory of Geo-Informatics of State Bureau of Surveying and Mapping, Chinese Academy of Surveying & Mapping, Beijing 100830, China;

2. College of Resource and Environment, Graduate School of the Chinese Academy of Science, Beijing 100049, China)

**Abstract:** A new semi-empirical model is presented for soil moisture content retrieval, using ENVISAT- ASAR and LANDSAT-TM data collaboratively. Firstly, a back propagation (BP) neural network algorithm (GA) is introduced, and a genetic algorithm is applied to optimize the weights of the node of BP neural network. Then the TM bands (TM3, TM4, TM6) and ASAR data (VV, VH, VH/VV) are taken as the input of the GA-BP neural network, and the output corresponds to the ground soil moisture. The partial field measurements of soil moisture are used as training samples to train the network and to achieve the map of soil moisture distribution. The field measurements are used to test the validity of the BP neural network algorithm and effectiveness of the active and passive remote sensing cooperative inversion. The comparison between the inversion using single data set (TM or ASAR), and the cooperative inversion of active and passive remote sensing data demonstrates that the new algorithm is more effective, and shows considerable potential in soil moisture retrieval by integrating active and passive remote sensing data.

**Key words:** active and passive remote sensing; GA-BP neural network; soil moisture; inversion

**PACS:** 92.40. Lg

### 引言

在陆面-大气相互作用过程中,土壤水分是调控地-气反馈的最重要参数之一,直接控制着地表与大

收稿日期:2011-06-21,修回日期:2011-12-18

Received date: 2011-06-21, revised date: 2011-12-18

基金项目:国家重点基础研究发展计划(973项目)“陆表生态环境要素主被动遥感协同反演理论与方法”(2007CB714407),中国自然科学基金(41101321),中国测绘科学研究院科研基本业务经费(7771023 和 7771017)联合资助

**Foundation item:** Supported by National Basic Research Program of China (973 Program, GrantNo. 2007CB714407); National Science Foundation for Young Scientists of China (Grant No. 41101321) and Basic Research Program of the Chinese Academy of Surveying and Mapping (Grant No. 7771023 and 7771017)

作者简介:余 凡(1982-),男,湖北孝感人,助理研究员,从事光学雷达遥感的协同反演研究. E-mail:yufan021@126.com.

气之间水、热量的输送和平衡。土壤水分的估算也是其他学科,比如气象学、水文学、生态学和农业等关注的重点研究对象。因此,探讨一套客观、动态、实时的土壤水分监测方法具有重要意义。

传统土壤水分监测方法很难在大范围、高效率和实时进行常规测量。而遥感技术由于其宏观、动态、实时、多源的特点,已在地表土壤水分研究中蓬勃开展。其中,光学与雷达遥感是两种不同的土壤水分获取手段,能从不同的角度反映地表的土壤水分信息。光学遥感是通过地物反射辐射特征变化来模拟地表覆盖类型、地表温度、土壤热惯量、地表蒸散发与土壤含水量之间的关系来获取土壤水分<sup>[1]</sup>,是一种间接的模式。微波遥感基本原理是通过土壤介电常数建立地表后向散射系数与土壤水分之间的联系<sup>[2]</sup>,物理意义明确,但常受到地表粗糙度、植被的干扰。可见,光学与微波遥感在土壤水分反演机理上完全不同,两者各有优势与不足。尽管光学和微波遥感数据都隐含土壤水分信息,但是要直接用严格的数学表达式建立两者之间的联系,来协同反演土壤水分,具有相当的难度,且存在较大的不确定性。

神经元网络算法具有极强的容错性、自组织性、非线性模拟和泛映射能力。它是一种‘黑匣’式的映射,无需明确两者之间的确切关系,只需要‘现象上’存在关系即可,非常适合解决非线性的复杂问题<sup>[3]</sup>。遗传算法( Genetic Algorithm, GA)是基于自然选择和遗传学机理的迭代自适应概率搜索算法,它是一种全局优化算法,可克服人工神经网络自身的缺陷,并进一步提高网络训练速度和预测精度。

基于以上考虑,提出了一种基于 GA-BP 神经网络优化的主被动遥感协同反演土壤水分方法(流程图如图 1)。该方法首先建立一个 BP 神经网络,并利用遗传算法对网络的节点权值进行了优化;然后将光学遥感数据、微波遥感数据作为遗传神经网络的输入参数,土壤水分作为输出参数,反演得到了研究区的地表土壤水分布图;并在实测数据的支持下,将本文方法与非遗传神经网络的 TVDI 光学模型和农作物微波辐射模型反演土壤水分方法,以及与仅用单一的光学或微波数据作为遗传神经网络的输入的结果做了比较,以验证本文优化算法以及主被动遥感协同反演的有效性。

## 1 主被动协同算法研究

### 1.1 协同机理分析

本文的研究目标是提取土壤水分信息,对于光

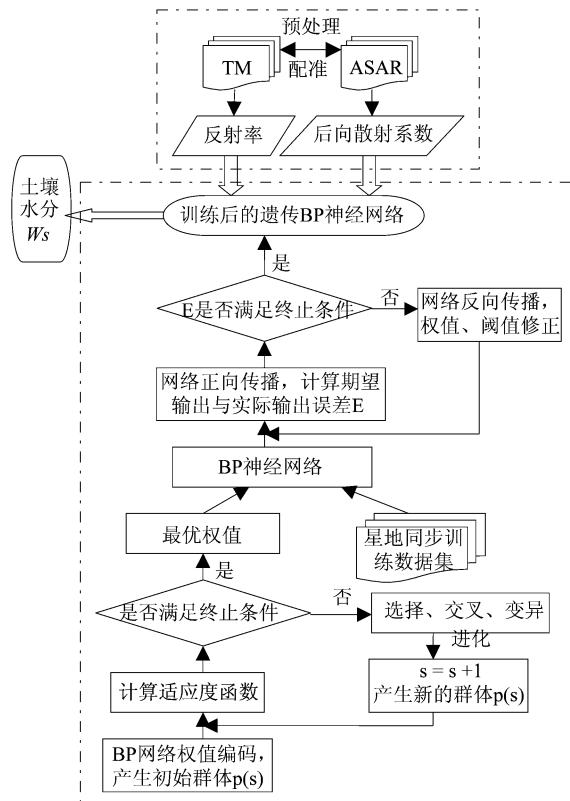


图 1 GA-BP 神经网络反演土壤水分流程图

Fig. 1 The flow chart of the soil moisture inversion by the GA-BP neural networks

学影像,由于土壤水分与地表反射率、地表温度密切相关,可从地物波谱分析入手,选择与土壤水信息有关的波段。众所周知, TM3(0.63~0.69 μm)与 TM4(0.76~0.90 μm)是反映植被信息的首选波段,分别对应着植物叶绿素强烈吸收与植物高反射; TM5(1.55~1.75 μm)与 TM7(2.08~2.35 μm)对水分信息反映敏感;而反映温度信息的热红外(TM6)与土壤水分信息相关性密切。因此,由这些波段数据所构成的遥感信息往往可以用于提取土壤水分信息。国内外成熟的光学反演土壤水分模型多是依靠以上几个波段建立,比如热惯量法、植被指数法、温度-植被指数法、湿度指数法、高光谱法。

此外,由于雷达信号(后向散射系数)与物体表面的电学性质(复介电常数)密切相关,而水的介电常数较大,随着地表水分含量的变化,可以使雷达后向回波出现明显变化<sup>[4]</sup>。因此,雷达遥感可以从完全不同于光学遥感的角度,作为监测土壤水分的重要信息源。

不考虑雷达系统误差的情况下,目标的雷达后向散射系数除了受目标复介电常数  $\epsilon_m$  的影响外,还主要受到入射波长  $\lambda$ 、入射角  $\theta$ 、地表植被覆盖参数

$Veg$ 、地表粗糙度  $S_r$  等的影响,可表达为:

$$\sigma^o = f(\lambda, \theta, Veg, S_r, \varepsilon_m) \quad . \quad (1)$$

一般说来,波长  $\lambda$  越大,雷达信号穿透性越好,越有利于雷达信号穿透植被获取地表的土壤水分信息;入射角  $\theta$  越大,穿深能力越小;植被覆盖参数  $Veg$  包括植被覆盖度(密度)、植被表面结构(粗糙度)、植被的含水量等,也是影响雷达能否实现土壤水分反演的关键.此外,地表粗糙度  $S_r$  对雷达后向散射系数的影响也较大,地表粗糙度越大,则后向散射系数越强,而土壤水分的信号则相对变微弱,不利于土壤水分信息的获取.正因为雷达信号与土壤水分之间有着机理上的必然联系,国内外学者研究了多种不同的微波散射理论模型、经验-半经验模型反演土壤水分<sup>[5]</sup>.

## 1.2 遗传神经元网络算法

神经网络和遗传算法都是人们仿效生物处理模式,并从中获取解决实际复杂问题的方法.随着对两种算法的不断深入研究,发现各自存在的问题.BP 神经网络具有自适应学习能力,有很强的非线性模拟能力,但是容易陷入局部极小,同时网络的设计没有理论上的指导,依赖设计者的经验和样本空间的反复试验,限制了网络求得全局最优解的可能性;遗传算法不具备自适应学习能力,但是它能够收敛得到全局最优解,鲁棒性好.因此将神经网络和遗传算法结合起来不仅能发挥神经网络的泛化映射能力,而且使神经网络具有较快的收敛性、全局优化能力和较强的学习能力<sup>[6]</sup>.

BP 神经网络算法的数学描述如下<sup>[7]</sup>:

$$\begin{cases} \min E_1(w, v, \theta, r) = \frac{1}{2} \sum_{k=1}^M \sum_{t=1}^n [y_k(t) - \hat{y}_k(t)]^2 \\ s.t.: \in R^{m \times p}, v \in R^{n \times p}, \theta \in R^p, r \in R^n \end{cases}, \quad (2)$$

其中  $E_1$  为网络总的误差,  $y_k(t)$  为期望输出,  $\hat{y}_k(t)$  为网络实际输出.

$$\hat{y}_k(t) = f[\sum_{i=1}^p v_{jt} \times f[\sum_{i=1}^m w_{ij} \times x_i(t) + \theta_j]] + r_i \quad . \quad (3)$$

设  $E_2 = \frac{1}{N - N_{1k=N_t}} \sum_{k=1}^N \sum_{t=1}^n [y_k(t) - \hat{y}_k(t)]^2$  为检测样本平均均方误差,表示对网络输出数据可靠性的估计.  $E_2$  越小,网络输出的可靠性越大.

本文采用遗传算法对 BP 神经网络进行优化步骤如下:

(1) 初始化 BP 神经网络,确定输出节点个数  $X$ , $Y$ ,隐含层数  $H$ ,训练次数  $N$ ,训练误差  $\varepsilon$  等.

(2) 遗传编码,确定遗传算法的种群规模  $P$ ,染

色体个数  $n$  与最大迭代次数  $T$ ,交叉概率  $P_c$  与变异概率  $P_m$ ,将 BP 网络权值与阈值按一定顺序级联起来,作为遗传算法的一个染色体,其长度  $l$  为神经网络的权值个数和阈值个数之和,即:

$$l = H \times (X + Y) + H + Y \quad . \quad (4)$$

(3) 适应度函数计算,将 BP 网络的误差函数  $E$  作为适应度函数,计算种群中每一个染色体的适应度.

(4) 遗传进化,将交叉和变异算子作用于父代种群  $P_t$  产生子代种群  $Q_t$ ,并将两个种群联合在一起形成  $2n$  的种群  $R_t$ ,对具有  $2n$  规模的种群  $R_t$  进行非劣分类操作,按照拥挤选择算子的原则产生下一代种群  $P_{t+1}$ ,并将副本复制到  $P'$ .

(5) 重复(2)~(4)步,直到满足终止条件为止,至此,将  $P'$  中最优个体解码,作为 BP 网络的初始权值和阈值.

GA 的进化代数要求不是很大,因为 GA-BP 神经网络中只要求 GA 为 BP 神经网络提供具有全局性的进化较好解,并不要求 GA 进化至权值、域值的最优解.

## 2 地表土壤水分反演试验

### 2.1 研究区与数据

#### (1) 研究区简介

研究区位于甘肃黑河流域中游的张掖地区盈科农业灌区,属河西走廊的低平原部分,中心位置为:北纬  $38.8653^\circ$ ,东经  $100.4198^\circ$ ,海拔  $1519$  m.该地区处温带干旱荒漠气候区,多年平均降水量为  $121.5$  mm,年潜在蒸发量超过  $2340$  mm,为降雨量的 20 余倍.盈科灌区为荒漠中的一片绿洲,主要是由人工灌溉的农田组成,土壤质地为沙土占  $16.7\%$ ,泥沙占  $74.8\%$ ,粘土占  $8.5\%$ .在实验进行的 2008 年 6 月和 7 月,灌区主要农作物为玉米.

#### (2) 地面测量数据

本文所用的数据来源于“黑河综合遥感联合试验”.研究区大小为  $1.5 \text{ km} \times 1.5 \text{ km}$ ,共有 32 个实测样点,由一个样方和一条样带组成,样方位于研究区中部偏上的位置,大小为  $180 \text{ m} \times 180 \text{ m}$ ,均匀分布有  $4 \times 4$  个点,点间距  $60$  m.样带有 15 个样点,点间距也是  $60$  m,沿东西方向分布于研究区(图 2).每个样点分别对表层土壤水分、地表粗糙度和植被参数进行了测量.由于对雷达信号敏感的主要是表层的土壤水分,本次实验采用 TDR 和环刀取样法获取表层  $0 \sim 5$  cm 土壤体积含水量,每个样点都测量



图 2 研究区地理位置示意图  
Fig. 2 Sketch map of location of the study area

5~10 个点取平均. 采用粗糙度板测量粗糙度参数, 获取了均方根高度  $s$  和相关长度  $l$ . 地面测量的植被参数主要有单片叶子重量含水量、单片叶面积、叶密度参数、叶片生理生化参数、叶片结构参数等.

### (3) 卫星数据

卫星数据分别为 2008 年 7 月 7 日 11 点 42 分 31 秒过境的 TM 和 2008 年 7 月 11 日 11 点 26 分 15 秒过境的 ASAR, 后者在研究区的入射角为 21° 左右. ASAR (Advanced Synthetic Aperture Radar) 是欧空局 ENVISAT-1 卫星上载有的合成孔径雷达, 为 C 波段(中心波长 5.63 cm)、多极化、7 个角度的传感器, 共有五种工作模式. 本文所用的 ASAR 数据产品代号为 ASAR\_APP\_1P, 传感器模式为 Alternating Polarisation, 有 VV 和 VH 两种极化方式, 地面分辨率为  $12.5 \text{ m} \times 12.5 \text{ m}$ .

本文两景遥感影像的获取时间相差 4 天. 地面土壤水分数据的获取时间为 7 月 9 日和 7 月 11 日, 其中 7 月 11 日的土壤水分试验与 ASAR 同步. 4 天内没有降雨, 且据试验站和附近 2 个自动观测装置观测, 4 天内土壤水分变化在  $0.02 \text{ g/cm}^3$  以下. 另于 7 月 9~11 日在实验样区内 6 样点, 所获得的土壤水分体积含水量变化为: 裸露地表由于本身土壤水分含量低, 基本没有变化; 植被覆盖地表变化也不大, 最大变化率小于 3%. 可见, 研究区土壤水分变化较小, 对本文的主被动协同反演影响有限.

## 2.2 反演试验

遗传神经网络算法采用 MATLAB 语言编写, 优

化算法的部分代码取自文献[8]. 在反演土壤水分时, 首先将 ASAR 图像重采样成  $30 \text{ m} \times 30 \text{ m}$ , 与 TM 影像分辨率一致, 并分别对两者进行几何校正与配准. 然后选择 TM3、TM4、TM6 和 ASAR 的 VV、VH、及两者比值(VH/VV)作为网络输入波段. 其中 VH/VV 在雷达成射角一定的情况下其后向散射系数仅与地表粗糙度有关.

本次试验的土壤水分实测样点共 32 个, 依据文献[9]中训练和验证数据的选取方法, 将 32 个点从大到小依次排列, 然后按照 2:1 的比例分成 2 个部分, 其中 21 个点用于网络的训练, 11 个点用于网络的验证. 取点时基本保证每隔 2 个训练点取 1 个验证点.

为提高本文模型中遗传算法的搜索效率, 在分析种群规模、染色体长度、适应度函数等参数的基础上, 确定遗传算法的进化代数为 100 代; BP 神经网络的设置为 3 层, 输入层 6 个节点; 隐含层神经元个数设置为 10; 输出层有 1 个节点. 选择双正切函数 (sigmoid) 作为输入层和隐含层的激励函数, 输出函数为线性函数, 训练次数为 2000 次. 设计好 BP 神经网络后, 采用遗传算法对 BP 神经网络的权值进行优化, 取得一组最优的权值, 然后以此作为 BP 网络的初始权值, 利用训练数据集对网络进行训练, 并采用 TM 数据和 ASAR 数据作为输入来反演土壤水分. 图 3 为 GA-BP 神经网络反演的地表土壤水分布图.

由于试验在 6~7 月份进行, 正值西部地区夏季, 干旱少雨, 农业主要依靠灌溉. 由图 3 可知, 中间最亮的几个点受雷达斑点噪声影响, 所得土壤水分值偏大; 图中上半部分呈亮色, 为灌溉不久的农田, 田间持水量比较高, 表层土壤水含量在  $0.3 \sim 0.5 \text{ g/cm}^3$

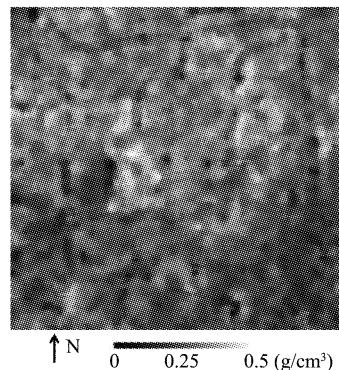


图 3 GA-BP 神经网络反演的地表土壤水分分布图  
Fig. 3 The distribution map of soil moisture inversed by the GA-BP neural networks

$\text{g}/\text{cm}^3$  之间;图中下半部分显暗色的部分为未灌溉作物,土壤水分含量较低(约  $0.05 \sim 0.2 \text{ g}/\text{cm}^3$  之间)。图中颜色最暗,形状近似于圆形的为荒芜的裸地,土壤含水量在  $0.05 \text{ g}/\text{cm}^3$  以下。

### 3 结果验证

为了验证本文优化算法以及主被动协同反演的有效性,采用两种途径,一是与非遗传神经网络的 TVDI 光学指数模型<sup>[10]</sup>和农作物微波辐射模型(Roo 模型)<sup>[11]</sup>常规方法反演的土壤水分进行比较;二是采用本文的优化算法,但将主被动遥感数据协同反演结果与仅用单一的光学或微波数据作为遗传神经网络的输入获得的反演结果相比较。

#### 3.1 优化算法的有效性分析

在实测数据的支持下,通过比较分析光学指数模型(TVDI)、雷达农作物模型(Roo 模型)与遗传 BP-神经网络(分别以光学、雷达数据作为输入,简写为 GA-BP-Optic、GA-BP-Microwave)反演得到土壤水分精度,对本文的优化算法的有效性进行了验证。

TVDI 模型能综合利用植被指数与地表温度两种与土壤水分密切相关的参数,是一种比较有效的光学反演土壤水分方法,在国内外取得广泛应用。Roo 模型是在简化 MIMICS 模型的基础上,不考虑植被茎杆的影响,将植被做为一层处理,比较适合农作物覆盖区地表土壤水分的反演。

图 4 为利用 GA-BP 神经网络反演的结果与常规光学、雷达遥感分别反演的土壤水分结果绘制的散点图。图中横轴为实测土壤水分,纵轴为模型反演土壤水分。误差分析如表 1。

由图 4、表 1 可知,TV defense result with GA-BP-Optic is closer to the measured value than GA-BP-Optic, but the relative error of GA-BP-Optic is larger.

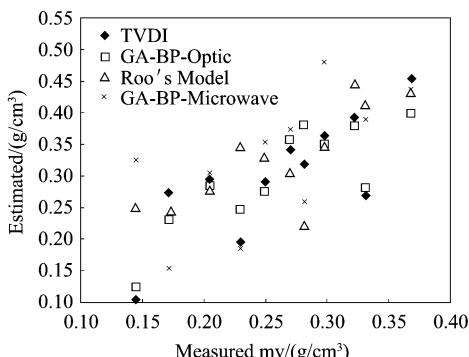


图 4 GA-BP 神经网络与 TVDI、Roo 模型反演对比图  
Fig. 4 Comparisons among the GA-BP neural network, the TVDI and Roo's model

表 1 GA-BP 神经网络与 NDVI-Ts、Roo 模型反演精度对比  
Table 1 The inversion precision of the GA-BP neural network models, TVDI and the Roo's model

算法	平均相对误差	均方根误差(RMS)	相关系数( $R^2$ )
TV defense	26.2%	0.067	0.64
GA-BP-Optic	21.1%	0.059	0.69
Roo's Model	37.2%	0.101	0.43
GA-BP-Microwave	32.8%	0.081	0.58

根误差更小,相关系数更大,后者精度稍高;相对于实测值,Roo 模型和 GA-BP-Microwave 反演的土壤水分误差都较大,尤其是 Roo 模型的均方根误差达  $0.101 \text{ g}/\text{cm}^3$ ,相关系数仅 0.43,这可能是由于 Roo 模型是基于微波辐射传输的理论模型,参数较多,计算复杂,很多参数在野外难以精确获取,同时模型的假设条件在野外也不易完全满足。相对来说,GA-BP-Microwave 的反演结果要明显好一些,与实测土壤水分的相关系数达到 0.58,这可能由于 GA-BP 神经网络具有较强的非线性模拟能力,对测量参数的要求较低。

由此可见,GA-BP 神经网络相对常规光学、雷达反演方法具有更高的反演精度,表明本文优化算法是有效的。

#### 3.2 主被动协同反演效果验证

将本文提出的光学和雷达数据同时作为输入,并利用 GA-BP 神经网络优化算法反演土壤水分(GA-BP-Mixed),与单一遥感数据(GA-BP-Optic 和 GA-BP-Microwave)的反演结果做比较,对主被动协同反演的效果进行验证。图 5 为 GA-BP-Mixed 与 GA-BP-Optic、GA-BP-Microwave 反演土壤水分的散点图,表 2 为误差分析比表。

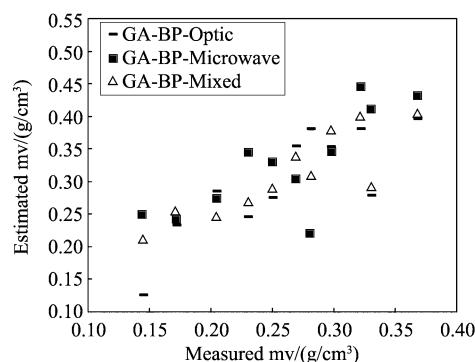


图 5 GA-BP-Mixed 与 GA-BP-Optic、GA-BP-Microwave 反演对比图  
Fig. 5 Comparisons among the GA-BP-Mixed, GA-BP-Optic and GA-BP-Microwave model

**表 2 GA-BP-Mixed 与 GA-BP-Optic, GA-BP-Microwave 的反演精度**

**Table 2 The inversion precision of the GA-BP-Mixed, GA-BP-Optic and GA-BP-Microwave model**

算法	平均相对误差	均方根误差(RMS) g/cm <sup>3</sup>	相关系数 (R <sup>2</sup> )
GA-BP-Mixed	17.5%	0.05	0.74
GA-BP-Optic	21.1%	0.059	0.69
GA-BP-Microwave	32.8%	0.081	0.58

由图 5、表 2 可知, 基于遗传神经网络的光学、雷达数据协同反演的精度明显要高于单一数据源反演的精度, 表明光学和雷达协同反演能够发挥两者土壤水分反演的各自优势, 提高反演精度, 具有互补的效果.

#### 4 结论

提出了一种基于 GA-BP 神经网络的主被动遥感数据协同反演土壤水分算法, 该算法首先建立一个 BP 神经网络, 并采用遗传算法对 BP 网络的节点权值进行了优化, 获取一个最优权值作为 BP 网络的初始权值. 完成 BP 网络训练后, 以光学和雷达遥感数据作为网络的输入, 反演生成了研究区的土壤水分布图. 经实测数据验证, 结果表明:

① 经与 TVDI 光学模型和 Roo 微波辐射模型反演土壤水分方法的对比, 新优化算法能取得更好的反演精度, 能生成区域内土壤水分, 且对野外测量参数的依赖也比较低.

② 经与仅用单一的光学或微波数据作为遗传神经网络的输入相比较, 基于遗传神经网络的 TM 和 ASAR 数据协同反演精度明显要高于两者单独反演时的精度. 这表明基于遗传神经网络的光学和微波遥感数据协同反演是有效的, 两者在反演上有互补的效果, 体现出光学和微波遥感在协同反演地表土壤水分上的巨大潜力.

③ 研究区地面试验数据是点数据, 而 TM 和 ASAR 遥感观测获取的是整个面上的信息, 两者直接等同会产生一定的误差, 尚待进一步研究点-面间的尺度效应问题.

④ 本文是采用优化算法对主被动遥感数据协

同反演土壤水分的初步尝试, 利用有限的遥感影像数据和地面实测数据完成了光学与雷达协同反演土壤水分算法的建模及初步验证, 虽然较明显地提高了土壤水分反演的精度, 但是由于野外实测数据偏少, 在利用遗传神经网络反演时存在不稳定的问题, 反演过程中可能存在一定的偏差.

#### REFERENCES

- [1] Kogan F N. Global drought watch from space [J]. *Bulletin of the American Meteorological Society*, 1997, **78**: 621–636.
- [2] Ulaby F T, Moore R K, Fung A K. *Microwave remote sensing. Volume II : Radar Remote Sensing and surface Scattering and Emission Theory* [M]. Addison-Wesley Publishing Company, 1982.
- [3] Pan H. Application of BP neural network based on genetic algorithm [J]. *Computer Application*, 2005, **25** (12) : 2777 – 2779.
- [4] ZHAO Ying-Shi. *Analysis and its method of applied remote sensing* [M]. Beijing: Science Press(赵英时. 遥感应用分析原理与方法. 北京: 科学出版社), 2003: 138 – 144.
- [5] Moran M S, Daniel C H. Soil moisture evaluation using multi-temporal synthetic aperture radar (SAR) in semiarid rangeland [J]. *Agriculture and Forest Meteorology*, 2000, **105**: 69 – 80.
- [6] LI Z, ZHANG J T. Application of the combination of genetic algorithm and artificial neural network on crop yield estimation in Jilin Province. *Acta Ecologica Sinica*, 2001, **21** (5) : 716 – 720.
- [7] Pan H. Application of BP neural network based on genetic algorithm [J]. *Computer application*, 2005, **25** (12) : 33 – 45.
- [8] MATLAB. [EB-OL] <http://www.ilovematlab.cn/>.
- [9] HASI Ba-Gan, MA Jian-Wen, ZHOU Zi-Jiang. Artificial neural network method used for weather and AVHRR thermal data classification [J]. *Journal of the Graduate School of the Chinese Academy of Sciences* (哈斯巴干, 马建文, 周自江. 基于气象数据与 AVHRR 热红外数据的人工神经网络分类方法. 中国科学院研究生院学报), 2003, **2**(3) : 328 – 333.
- [10] LIU Liang-Yun, ZHANG Bin, ZHEN Lan-Fen. Target classification and soil water content regression using land surface temperature (LST) and Vegetation Index (VI) [J]. *J. Infrared Millim. Waves* (刘良云, 张兵, 郑兰芬. 利用温度和植被指数进行地物分类和土壤水分反演. 红外和毫米波学报), 2002, **21**(4) : 269 – 273.
- [11] Roo D R, YANG D. A semi-empirical backscattering model at L-band and C-band for a soybean canopy with soil moisture inversion [J]. *IEEE Trans. Geosci. Remote Sensing*, 2001, **39** (4) : 864 – 872.