

# 人工神经网络模型反演植被生物量参数<sup>\*</sup>

金亚秋 刘长龙

(复旦大学波散射和遥感中心, 电子工程系 上海 200433)

**摘 要** 该文利用 1988 年小麦生长期中生物量参数和微波(10.2GHz)主被动遥感实测数据, 作为输入输出  $I/O$  矢量对, 训练人工神经网络为参数反演模型。然后用 1989 年小麦生长期中微波主被动遥感实测数据和该神经网络模型, 来反演其生物量参数在整个 1989 年生长期中的变化。反演结果与遥感实测结果作了很好的比较。

**关键词** 人工神经网络模型(ANN), 遥感反演, 生物量参数

## 1 引 言

定量遥感学包括了因果关系数值模拟的正问题<sup>[1]</sup>和参数反演结构重建的逆问题<sup>[2]</sup>。如何从遥感观测图象和数据中定量提取遥感对象及其环境的物理、几何、生物等特征性参数, 是遥感应用的主要目标。用遥感对地表植被经济系统(如生物量参数的变化)的监视和评估, 有着十分广泛的实际应用。主被动遥感观测到的植被层散射和热辐射包括了植被散射元的多次散射、粗糙下垫界面的散射等互相耦合的一个高度非线性化的过程。非线性关系的反演, 是现今反演研究的若干方法如正规化光滑法, Backus-Gilbert 法, D 矩阵法<sup>[2]</sup>等难以解决的。

近年来, 人工神经网络(ANN)理论已引起了广泛的兴趣<sup>[3]</sup>, 在计算机科学、信息技术、人工智能、目标识别、生物医学工程等领域中都得到了十分重要的研究和应用。ANN 模拟人脑智能的特点和结构, 进行抽象的简化和模拟, 把神经元连接成高度相关的多层网络结构, 由各神经元构成的并行协同处理的网络系统所能实现的行为是极端丰富的。ANN 的原理、特点及其算法适合于大量高维遥感数据自动处理的参数反演过程, 而用通常人工参数匹配拟合是无法完成的。ANN 用已知的多对参数值/观察值进行 ANN 的学习训练。这是一种多次反馈和迭代的自我学习过程。ANN 也可看成输入输出  $I/O$  的非线性矢量函数进行计算的最优化结构。一旦 ANN 学习训练完成, 就可用它来有效地反演大量遥感数据的参数系统。近年来用

ANN 进行遥感参数反演已进行了一些研究。Ishimaru 等<sup>[4]</sup>曾用 ANN 反演随机粗糙面散射理论中的相关函数的方差和相关长度。Tsang 等<sup>[5]</sup>曾用 ANN 重建冰雪参数的结构, 但这些研究都限于理论试验, 未能对真实遥感数据反演给出合乎实际的结论。我们曾提出从主被动遥感的热发射率(水平和垂直极化的热发射率  $e_h, e_v$ )和后向散射系数(水平和垂直同极化后向散射系数  $\sigma_{hh}, \sigma_{vv}$ )的观测值, 训练 ANN。然后再用已训练的 ANN 和遥感观测值(后向散射和热发射)来反演植被在整个生长期间生物量参数的变化<sup>[6]</sup>。

对主被动微波遥感敏感的生物量参数包括: 植被高度  $h$  (cm), 植被含水量  $d_w$  (用水柱高度 mm 表示, 等同于常用的  $kg/m^2$ ), 植被干重量比  $m_d$ , 以及下垫界面的体积湿度  $m_v$ 。植被的生物量和湿生物量通常由  $d_w$  和  $m_d$  定义。该文利用 1988 年小麦生长期中生物量参数 ( $h, d_w, m_d, m_v$ ) 和微波 (10.2GHz) 主被动遥感 ( $e_h, e_v, \sigma_{hh}, \sigma_{vv}$ ) 实测数据, 作为输入输出  $I/O$  矢量对, 训练人工神经网络为参数反演模型。然后用 1989 年小麦生长期中微波主被动遥感实测数据和该神经网络模型, 来反演其生物量参数在整个 1989 年生长期中的变化。反演结果与生物量参数实测结果作了很好的比较。

## 2 生物量参数的 ANN 反演

该文使用 ANN 网络多层感知器(MLP), 如图 1 示。这是一种前向神经网络, 由一个输入层, 一个隐层, 一个输出层组成, 层间以不同的权重连接。




图 1 ANN 结构示意图  
Fig.1 Geometry of the ANN

这样的神经网络经过训练后可以匹配任意一种输入输出之间的映射关系<sup>[3]</sup>。一旦 ANN 训练完毕，就可以用它来根据已知的观察值输出反演出合适的参数输入。

层为输入层，第 2 层为隐层，第 3 层为输出层。第  $l$  层神经元数用  $N_l$  表示(在训练和反演中，均选取  $N_1=4, N_2=27, N_3=4$ )。设现有  $M$  个样本输入 ( $I^{(1)}, \dots, I^{(M)}$ )和输出  $t^{(1)}, \dots, t^{(M)}$  的  $I/O$  对训练 ANN。当第  $k$  个样本输入时，第  $l$  层神经元的输入矢量为  $I^{(k)}(l)$ ，输出矢量为  $O^{(k)}(l)$ 。输入参数矢量  $I(l=1)$ 亦可表示成  $O(l=0)$ ，最终的输出矢量为  $O(l=3)$ ， $t$  表示要求的真实输出矢量。第  $l$  层中神经元  $i(1 \leq i \leq N_l)$ 以权重  $W_{ij}(l)$ 与相邻层(第  $l-1$ 层)中神经元  $j(1 \leq j \leq N_{l-1})$ 相连接。各权重可以通过已知输入和输出对进行训练学习而得到调整，使得网络的实际输出  $O(l=3)$ 与要求输出  $t$  之间的差异为极小。 $M$  个样本，即  $M$  天的实验测值(用  $M=200$ )。第  $k$  个样本输入  $I^{(k)}$ 即是第  $k$  天的参数矢量  $I^{(k)}=(h^{(k)}, d_w^{(k)}, m_d^{(k)}, m_v^{(k)})$ ，第  $k$  个样本输出  $t^{(k)}$ 即是第  $k$  天的遥感测值矢量  $t^{(k)}=(e_h^{(k)}, e_v^{(k)}, \alpha_{hh}^{(k)}, \alpha_v^{(k)})$ 。遥感的物理过程是具  $I^{(k)}$ 的对象产生观测  $t^{(k)}$ ，即是输入 ( $I^{(1)}, \dots, I^{(M)}$ )和输出 ( $t^{(1)}, \dots, t^{(M)}$ )成为  $I/O$  对。用迭代法来训练 ANN<sup>[4,5,6]</sup>，而后由观测  $t^{(k)}$ 和 ANN 来反演对应的  $I^{(k)}$ 。植被的生物量通常定义为：

图 1ANN 中，以  $l=1, 2, 3$  标记各层。第 1







图 2 1988 年和 1989 年小麦生物量参数  
(a)高度  $h$  (b)含水量  $d_w$  (c)干重量比  $m_d$  (d)下垫地表体积湿度  $m_v$

Fig.2 Biomass parameters of wheat in 1988 and 1989

$$\text{干生物量} = \frac{m_d d_w}{1 - m_d} \text{ (kg/m}^2\text{)},$$

$$\text{湿生物量} = d_w + \frac{m_d d_w}{1 - m_d} \text{ (kg/m}^2\text{)} .$$

网络训练完成后, ANN 选定了固定的权重, 就可以进行反演工作。根据已知的另一组观察值输出矢量 ( $e_h, e_v, \sigma_{hh}, \sigma_{vv}$ ), 用多层 MLP 反演出与其对应的合适的参数输入矢量 ( $h, m_w, m_d, m_v$ )。迭代反演的优点在于它精度较高, 在反演时便于控制, 特别是它可以在反演过程中依据先验知识加入约束, 提高了反演的速度和精度。迭代时初值选取的合理和好坏对反演结果有很大的影响。该文根据参数在整个区间范围内上升(比如  $h, d_w, m_d$  3 个参数)或下降(比如  $m_v$  参数)的大致趋势来选用[0.05, 0.95] 范围内单调上升或下降的直线作为我们的初值。反演结果表明, 这样的选取较好。第二是反演时所加的约束。如果在一定范围内(通常是在早期)某参数值变化很小, 这使得网络将对该参数值不敏感, 导致某些点上反演结果可能有较大的误差。为了改进, 可在反演时加进一定的物理约束。

在我们的反演中, 我们根据农业经验对高度  $h$  加了约束, 一般而言, 早期相邻两天高度  $h$  的变化量不会超过某个值, 例如小麦在前 100 天中每天的变化不超过 1cm。

文献[7]用一台多通道狄克式辐射计和散射计组合的 RASAM 在 1987 年 12 月至 1989 年 7 月瑞典伯恩附近的农场实验基地上空 8m 处测量了多种农作物的主被动遥感数据及其地表植物的生物量参数。我们首先选用了 10.2GHz, 从 50°角(相对于垂直方向)测得的小麦生长期中(从 1987 年 12 月 21 日到 1988 年 7 月 18 日)26 天的生物量参数 ( $h, d_w, m_d, m_v$ ) 的实验测量值和相应的主被动遥感数据 ( $e_h, e_v, \sigma_{hh}, \sigma_{vv}$ ) 的观察值, 训练 ANN 作为反演模型。这些 1988 年的生物量参数 ( $h, d_w, m_d, m_v$ ) 由图 2 (a), (b), (c), (d) 中实心点给出; 相应的主被动遥感数据 ( $e_h, e_v, \sigma_{hh}, \sigma_{vv}$ ) 的观察值由图 3 (a), (b), (c), (d) 中实心点给出。生物量的增加导致热辐射的增强, 也可能使在某一观测角度上的后向散射增强或减弱。为了得到更多的样本数用于训练, 我们依据这 26 天的数据进行了插值, 而得到相邻 200 天(以

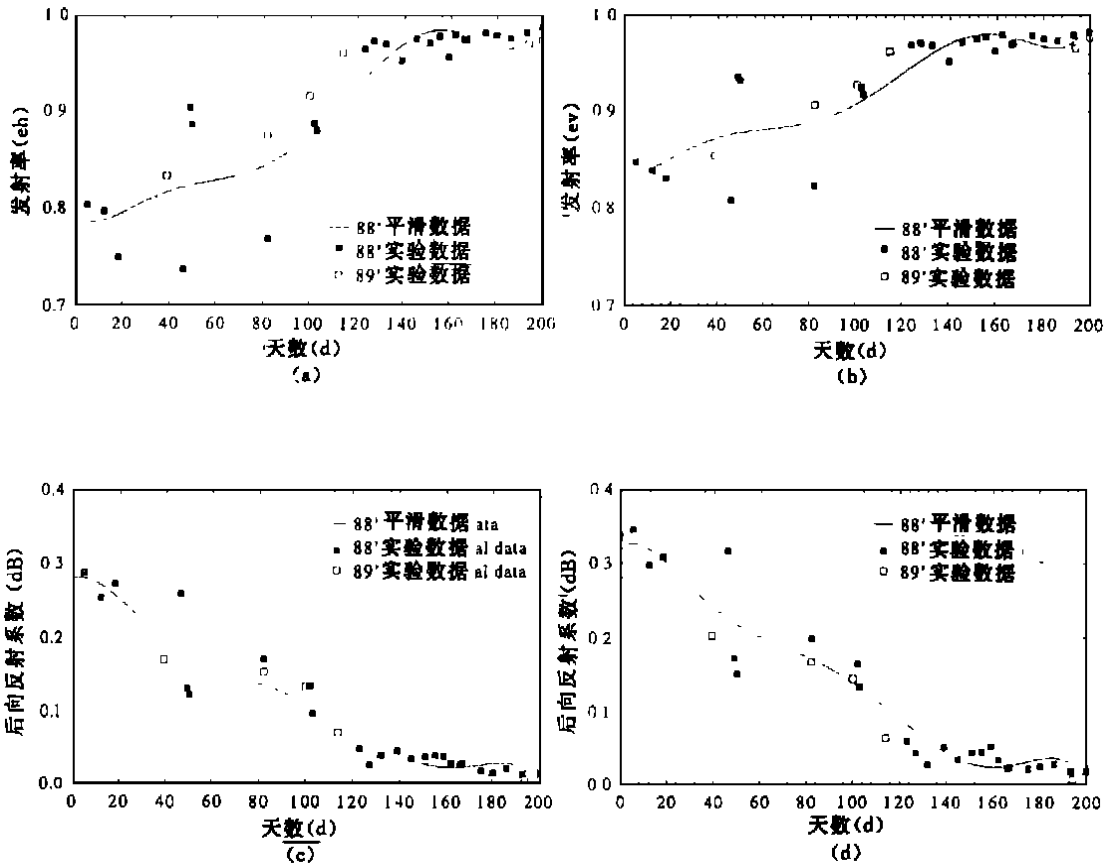


图 3 1988 年和 1989 年小麦生长期中的遥观测值  
 (a) 热发射率  $e_h$  (b) 热发射率  $e_v$  (c) 后向散射系数  $\sigma_{hh}$  (d) 后向散射系数  $\sigma_{vv}$

Fig. 3 Emissivity and backscattering from wheat canopy during 1988 and 1989

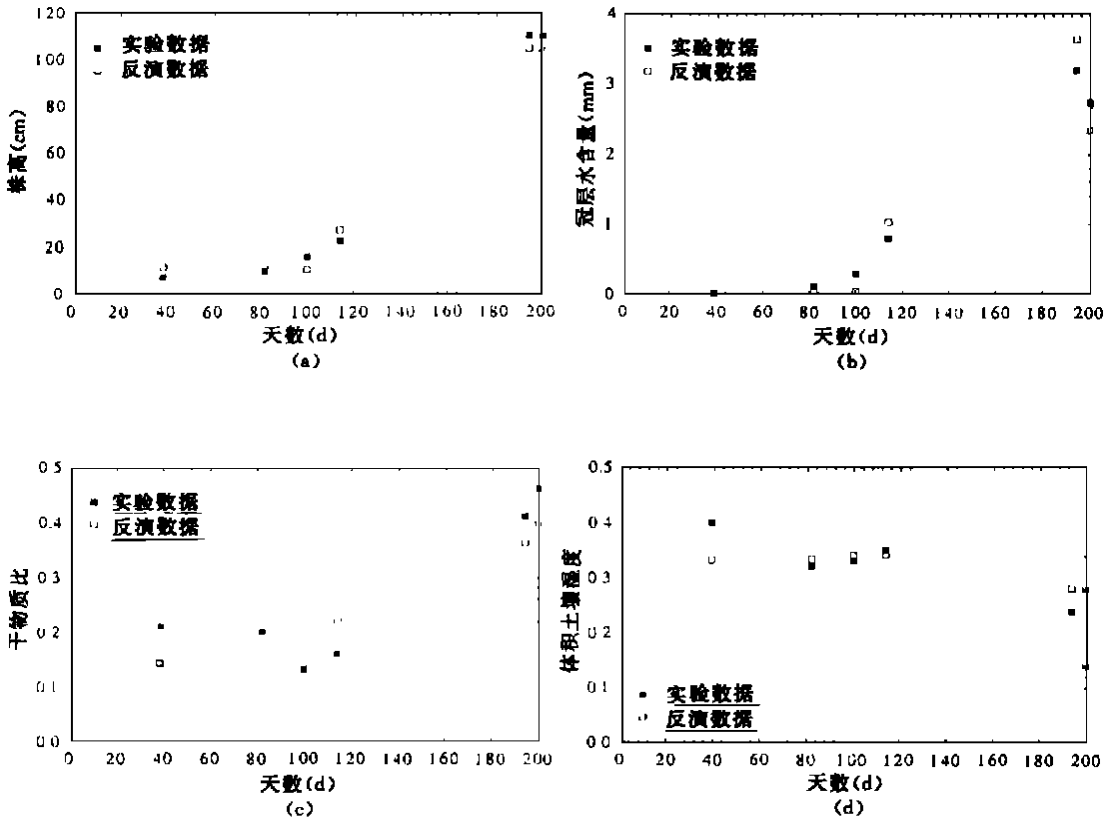


图 4 1989 年小麦生物量参数反演值与实际测值比较  
 (a)高度  $h$  (b) 含水量  $d_w$  (c) 干重量比  $m_d$  (d) 下垫地表体积湿度  $m_v$

Fig-4 Retrievals and data of wheat biomass parameters

1988 年 7 月 18 日(为第 200 天)的数据。同时为避开实际测量中由于随机取样或一些其它次要因素而可能产生的测值起伏,降低训练的难度以及在反演时便于加进物理约束,我们在插值前先对实验数据进行了光滑,平滑用于训练的数据中可能有的跳跃度。当然,对于土壤体积湿度这种可能会由于下雨或灌溉产生突变的参数,平滑会丢掉个别日子突变的信息,但由于对所有的参数都进行了平滑,我们可以认为在一定程度上平滑后的数据反映了整个生长期的变化情况。这样,我们用光滑后的 200 天数据,如图 2, 3 中的细实线,来训练 ANN。在 486 微机上训练 ANN 约需花机时一周。在 ANN 训练完成后,我们再选用 1989 年 2 月 8 日至 1989 年 7 月 21 日 6 天的 ( $e_h, e_v, \sigma_{hh}, \sigma_{vv}$ ) 离散数据,通过 ANN 来反演对应日子的生物量参数 ( $h, d_w, m_d, m_v$ )。图 2(a), (b), (c), (d) 中空点给出 1989 年小麦生物量参数 ( $h, d_w, m_d, m_v$ ) 的实际测量值,图 3 (a), (b), (c), (d), 中空点给出 1989 年小麦主被动遥感 ( $e_h, e_v, \sigma_{hh}, \sigma_{vv}$ ) 实际测量值。图 4(a), (b), (c), (d) 给出 1989 年小麦生物量参数 ( $h, d_w, m_d, m_v$ ) 的

ANN 反演值(空心点)和实际测量值(实心点)。比较两者,反演是好的。反演过程只需很短的时间。

### 3 结 论

该文提出了应用人工神经网络方法来反演生物量参数在整个生长期中的变化。这是一种非线性反演。我们利用 1988 年小麦生长期中 4 种生物量参数和微波双极化主被动遥感实测数据,作为输入输出  $I/O$  矢量对,训练人工神经网络为参数反演模型。然后用 1989 年小麦生长期中微波主被动遥感实测数据和该神经网络模型,来反演其生物量参数在整个 1989 年生长期中的变化。反演结果与遥感实测结果作了很好的比较。我们的研究表明,ANN 可以用来从遥感数据中反演整个生长期过程中的植被生物量参数。这种方法完全适用于 SIR-1, ERS-1 等航天遥感的高维数据(如多天,多极化,多视角,多频段等)中地表参数的反演研究。尽管 ANN 的训练需花费很长的时间,但一旦训练完成后,就可用迭代梯度法很快地完成反演。加入约

束条件,可以加速反演并得到更好的反演值。这是一种可用于高维遥感数据定量信息处理的有用方法。在没有完整的实验数据时,可以应用遥感数据模拟的正问题研究,利用仿真数据来进行同样的工作。

## 参 考 文 献

- [1] 金亚秋. 电磁散射和热辐射的遥感理论. 北京: 科学出版社, 1993.
- [2] 金亚秋. 矢量辐射传输理论和参数反演. 郑州: 河南科技出版社, 1994, 245—289.
- [3] Rogers S K, Kabrisky M. An Introduction to Biological and Artificial Neural Networks for Pattern Recognition. Washington: SPIE Opt. Eng. Press, 1991, Chapter 3—4.
- [4] Yoshitomi K, Ishimaru A, Hwang J N, Chen J S. Surface Roughness Determination Using Spectral Correlations of Scattered Intensities and an Artificial Neural Network Technique. *IEEE Trans. on Ap.*, 1993, AP-41 (4): 498—502.
- [5] Tsang L, Chen Z, Oh S, Marks II R J, Chang A T C. Inversion of Snow Parameters from Passive Microwave Remote Sensing Measurements by a Neural Network Trained with a Multiple Scattering Model. *IEEE Trans. on Geosci. Rem. Sens.*, 1992, GORS-30 (5): 842—852.
- [6] Jin Y. Q., Liu C. Biomass Retrieval from High-Dimensional Active/Passive Remote Sensing Data by Using Artificial Neural Network. *International Journal of Remote Sensing*, to be appeared in March 1997.
- [7] Hwang J N, Chan C H. Iterative Constrained Inversion of Neural Networks and Its Applications. in Proc. 24th Conf. Inform. Syst. and Sci. Princeton, NJ: March, 1990, 754—759.
- [8] Wegmuller U, Matzler C., Active and Passive Microwave Signature Catalog (2—12 GHz). Switzerland: University of Berne, 1993, 47—115.

## 作 者 简 介

金亚秋,男,1947年9月生。美国麻省理工学院电气工程与计算机科学系博士。现为上海复旦大学电子工程系教授,博士生导师。主要研究方向为电磁波散射传输和定量遥感理论,已在国内外发表个人专著3部,学术论文160篇。

## Biomass Parameter Retrieval by Using ANN Model

Jin Yaqiu Liu Changlong

(Dept. Electronic Engineering, Wave Scattering and Remote Sensing Centre, Fudan University)

**Abstract** By using the experimental data of microwave active /passive remote sensing and measurements of ground truth to train the artificial neuron network (ANN), a ANN model for retrieval of biomass parameters is developed. The ANN model was first trained by the data of wheat canopy in 1988. This ANN model was then used to retrieve biomass parameters of wheat canopy during growth in 1989. The retrieval results are well compared with the ground truth data.

**Key words** ANN model, Biomass parameter retrieval