

基于人工神经网络的植被覆盖 遥感反演方法研究

陈 涛^{1,2}, 牛瑞卿¹, 李平湘³, 张良培³

(1. 中国地质大学(武汉) 地球物理与空间信息学院, 湖北 武汉 430074;

2. 中国气象局农业气象保障与应用技术重点开放实验室, 河南 郑州 450003;

3. 武汉大学测绘遥感信息工程国家重点实验室, 湖北 武汉 430079)

摘要:使用新型遥感数据——“北京一号”小卫星数据,采用 BP 神经网络对密云水库流域内的植被覆盖进行反演,并将结果与传统回归分析法和 NDVI 像元二分法进行比较。结果表明:在山区植被信息遥感反演算法中,神经网络方法以其对非线性过程的精确模拟而具有比传统算法更高的精度,尤其对于遥感反演算法难度较大的山区植被覆盖信息提取效果较好。

关 键 词:植被覆盖;BP 神经网络;“北京一号”;遥感反演;密云水库流域

中图分类号:TP 79 **文献标志码:**A **文章编号:**1004-0323(2010)01-0024-07

1 引 言

植被覆盖度定义为植被(包括叶、茎、枝)在地面的垂直投影面积占统计区总面积的百分比^[1],它是许多全球及区域水文气候模拟所需的重要信息,也是描述生态系统的重要参数。目前,对于植被覆盖的遥感反演有许多经验^[2-4]和半经验算法^[5-7]。一般来说,经验算法都是采用回归分析法进行二次或三次多项式拟合。其算法简单、计算时间短,可得到较稳定的结果,并且不会破坏算法的适用范围。但推导出的关系仅仅对具有确定关系式时所采用的数据及统计性质相同的统计数据才有效。因而许多经验算法都具有一定局限性,只适用于特定区域与特定植被类型,不具有普遍意义。

在以山区和丘陵为主的密云水库流域,由于地形等原因的共同作用,植被的光学特性远比平原地区复杂。用传统的线性回归方法很难确定它们之间的非线性关系,并且对于这些非线性回归需要知道非线性过程的一些先验知识,这些先验知识一般又难以获得。人工神经网络则可以突破这些限制,灵

活地模拟大量的非线性或线性过程^[8-10],这些也正是人工神经网络的优势所在。

Weiss^[11]等利用神经网络在基于 Vegetation/Spot4 数据在反演一些生物物理变量时,发现反演结果精度较高,用来进行植被覆盖等生物物理变量反演可行,结果可靠。Bacour^[12]等基于 ENVISAT-MERIS 在计算地面生物变量时,发现神经网络的优势在于用它可以获得比传统的方法如 MODIS 算法更好的反演精度,同时证明了 Weiss 等的结论,而且还证明利用神经网络可以在较大范围内进行植被覆盖的反演。Bacour 等还认为,在利用遥感数据反演地面植被覆盖等生物变量如植被覆盖、叶面积指数时,神经网络在线性传输函数方面比其它一些经验回归和半解析算法的精度要好。

此外,Abuelgasim^[13]等、Danson^[14]等、Fang & Liang^[15]等、Smith^[16]等都应用神经网络方法对地表植被覆盖进行了反演,结果都很成功。因此,可以说神经网络用于植被覆盖进行遥感反演是有效的、很有前途的一种方法。本文利用“北京一号”小卫星影像和实地观测数据,探讨应用 BP 神经网络建立植

收稿日期:2009-07-01;修订日期:2009-11-21

基金项目:中国气象局农业气象保障与应用技术重点开放实验室开放基金项目(AMF200908)、武汉大学测绘遥感信息工程国家重点实验室开放基金项目(09R02)、国家 863 计划项目(2007AA12Z160)、国家自然科学基金资助项目(40672205)、国家自然科学基金项目(40901205)资助。

作者简介:陈涛(1981—),男,讲师,博士,主要从事环境遥感监测及高光谱遥感信息处理方面研究。E-mail:tonychen21@gmail.com。

被覆盖信息遥感提取模型的方法。

2 研究区域概况

研究区域为位于北京市密云县东北部的密云水库及其控制流域。密云水库位于京郊密云县城北山区($40^{\circ}14' \sim 41^{\circ}05' \text{N}$ 和 $116^{\circ}07' \sim 117^{\circ}30' \text{E}$), 横跨潮河、白河主河道上, 距北京市中心约 100 km, 水库最大水面面积 188 km^2 。密云水库的控制流域主要为潮白河流域上游, 包括潮河和白河两条大的分支。流域面积为 $15\,788 \text{ km}^2$ 。水库蓄水区 内植被分布以森林为主, 有人工林和天然次生林(图 1)。

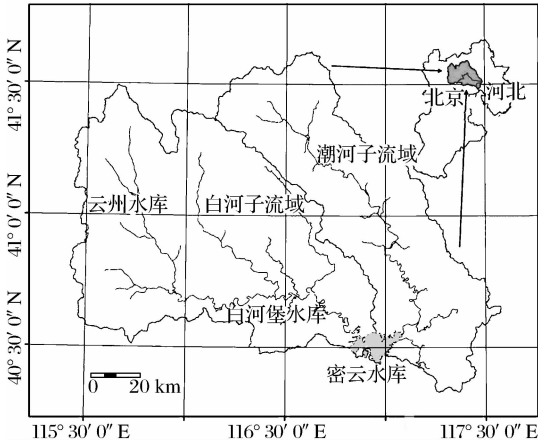


图 1 研究区示意图
Fig. 1 Map of the study area

3 数据获取与处理

3.1 数据准备

研究所使用的数据为 2005 年 11 月 14 日获取的一景“北京一号”小卫星多光谱影像(地面分辨率为 32 m); 流域内 $1:10$ 万地形图及流域边界图。

3.2 数据处理

首先利用 $1:10$ 万地形图 为参考, 采用二次多项式最小邻近法, 对“北京一号”小卫星遥感影像进行几何精纠正, 校正精度控制在 0.5 个像元以内。对影像进行几何精纠正后, 利用流域边界图, 从纠正后的影像中裁剪出密云水库流域范围内的影像(见图 1), 以上操作均利用 ERDAS 软件完成。

4 人工神经网络基本原理

人工神经网络(Artificial Neural Networks, 简称 ANN)由大量的、简单的处理单元(称为神经元)广泛地互相连接而形成复杂网络系统。现有的研究成果表明神经网络已具有人脑的一些基本特征, 如

学习、记忆和归纳等功能^[17,18]。它具有大规模并行处理、分布式储存和处理、自组织、自适应和自学习能力, 特别适合处理需要同时考虑许多因素和条件的、不精确和模糊的信息处理问题。因此人工神经网络在解决复杂的非线性问题时常具有独到的功效。人工神经网络通过“学习”的方式来实现某项特定任务。神经网络根据事先定义好的“学习规则”, 对所提供的特定样本进行学习, 在此过程中调整神经网络系统的内部结构, 从而达到记忆、归纳和联想的功能。人工神经网络技术发展至今, 已经建立了多种神经网络模型及相应的学习算法, 其中应用最广泛的是误差反向传递(Back Propagation)神经网络模型(简称 BP 模型)。




图 2 密云水库流域“北京一号”小卫星影像
Fig. 2 “Beijing-1” image of the study area

4.1 BP 神经网络结构

BP 神经网络的基本结构一般包含 3 层: 一个输入层, 一个隐含层(也称中间层) 和一个输出层; i 表示输入层的神经元数目, j 表示隐含层的神经元数目, k 表示输出层的神经元数目。每一层上的神经元都通过权值与相邻层上的各神经元实现全连接, 其基本结构如图 3 所示。




图 3 BP 神经网络结构图
Fig. 3 Diagram of the BP neural network

这种人工神经网络模型的特点是:各层神经元仅与相邻层神经元之间有连接;层内神经元无任何连接;各层神经元之间无反馈连接。

在该网络中,某一层的输出通过连接权值的加强或抑制传输到下一层的神经元。除输出层神经元外,网络中每层神经元的输入是前一层所有神经元的输出值的加权和。则对于隐含层节点的输入有:

$$I_j = \sum_i W_{ij} O_i \quad (1)$$

其中: W_{ij} 为输入层 i 节点与隐含层 j 节点的连接权值, O_i 为 i 节点的输出值,即 j 节点的输入值。对输出层有:

$$I_k = \sum_j W_{kj} O_j \quad (2)$$

其中: W_{kj} 为隐含层 j 节点与输出层 k 节点的连接权值, O_j 为 j 节点的输出值,其值由对数模型 Sigmoid(Log-Sigmoid) 激活得到:

$$O_j = \frac{1}{1 + e^{-I_j}} \quad (3)$$

输出层 k 节点的输出值由下式得到:

$$O_k = \frac{1}{1 + e^{-I_k}} \quad (4)$$

在该网络中,每个神经元是通过求输入权值和经激活函数传递结果来工作的,其数学描述如下:

$$G_i = f(t_i) = f(\sum_j W_{ij} G_j - \theta_i) \quad (5)$$

其中: G_i 是输出层中第 i 个神经元的输出; G_j 是前一层第 j 个神经元的输出; W_{ji} 为神经元 j 到神经元 i 的连接权值, $j, i = (j = 1, 2, \dots, n); \theta_i$ 为神经元 i 的阈值; $f(t_i)$ 为隐含层激活函数。

业已证明,若 BP 网络中隐含层节点可根据需要自由设定,那么 BP 网络可实现对任意连续函数的任意精度逼近^[18]。如将 BP 神经网络看成一个从输入到输出的映射,则该映射可以实现一个高度非线性问题的映射。可见 BP 模型通过对样本的学习或训练,可以解决复杂的非线性问题。

4.2 BP 神经网络学习算法实现

在 BP 神经网络算法中,整个网络的学习由输入信号的正向传播和误差的逆向传播两个过程组成。正向传播过程是指样本信号由输入层输入,经网络的权重、阈值和神经元的转移函数作用后,从输出层输出。如果输出值与期望值之间的误差大于规定量,则进行修正,转入误差反向传播阶段,即误差通过隐含层向输入层逐层返回,并将误差按“梯度下降”原则“分摊”给各层神经元,从而获得各层神经元的误差信号,作为修改权重的依据。以上两个过程

反复多次进行的权重不断修改的过程,也就是网络的训练过程,一直到网络的输出误差减小到允许值或达到设定的训练次数为止。具体描述如下:

(1) 各个神经元的输入和输出关系的转移函数是 f , 则各变量之间的关系为:

$$V_i^k = f(u_i^k) \quad (6)$$

$$u_i^k = \sum_j W_{ij} V_j^{k-1} \quad (7)$$

其中: u_i^k 为第 k 层第 i 单元输入的总和; V_i^k 为输出的总和; W_{ij} 为第 $k-1$ 层的第 j 个神经元到第 k 层的第 i 个神经元的连接权值。

(2) 定义误差函数 r 为期望输出值与实际输出值之差的平方和:

$$r = \frac{1}{2} \sum_j (V_j^m - y_j)^2 \quad (8)$$

其中: y_j 是输出层第 j 个神经元的期望输出, V_j^m 是实际输出。

由上式可得多层网络的训练方法是将某一样本加到输入层,这时按前传法则,它将逐个影响下一层的状态,最终得到一个输出 V_j^m , 如果这个输出与期望值不符,就产生误差信号,然后通过如下公式改变权值:

$$\Delta W_{ij} = -\epsilon \cdot d_j^k V_j^{k-1} \quad (9)$$

其中: d_j^k 为第 k 层的误差信号。

为改善网络的收敛特性,可采用权值更新量 ΔW_{ij} 的修正公式:

$$\Delta W_{ij}(t+1) = -\epsilon \cdot d_j^k V_j^{k-1} + \alpha \Delta W_{ij} t \quad (10)$$

其中: α 为动量因子。即在后一次的权值更新时适当考虑到上一次的权值更新值。

(3) 重复上述步骤直到误差函数满足要求或不再随迭代次数变化。

5 BP 神经网络植被覆盖信息提取模型

前人利用植被指数与植被覆盖建立经验关系,并获得了较好的效果^[2-7]。因此,本文利用 NDVI、SAVI、MSAVI 这些植被指数的各种组合来进行试算。实验中较复杂的函数可以用带有隐含层的神经网络来表达,隐含层的节点数是由函数的复杂程度来决定的。网络需要有足够的神经元去模拟函数。但是,过多的神经元又将导致训练时间的增加和过激。通过实验,得到适宜的神经元个数模拟传递函数,训练前相互关联的节点权重随机产生。神经网络在训练过程中既能采用大气顶的模拟反射率,也能采用去除大气效应后的辐亮度。

由于隐含层节点个数与自学习阶段的训练速度

和精度直接相关,通常随节点个数的增加,导致网络运算量增大,训练速度降低,但分类精度得到提高。对隐含层的层数和节点数的确定,目前仍没有统一的理论和方法,许多学者进行了理论上的研究。Cybenko^[19]曾指出,有两个隐含层就可以解决任何形式的分类问题,后来 Robert^[20]通过研究进一步指出:只有一个隐含层的神经网络,只要隐含层节点数目足够多,就可以以任意精度逼近一个非线性函数。但所有的研究一般是以全局误差趋于极小或小于预先给定的允许误差作为选取原则。在本文中,使用的是目前用来确定 BP 神经网络隐含层节点数比较有效的方法——试错法。本文分别组建了隐含层节点数从 2 到 20 的 BP 网络,采取了不同的转移函数和算法的搭配,具体见图 4 和图 5。两图中,a 表示植被指数 NDVI,b 表示 SAVI,c 表示 MSAVI。a、b 和 c 的各种组合即指植被指数 NDVI、SAVI 和 MSAVI 的不同组合。




图 4 相关系数随节点数变化图

Fig. 4 Correlation coefficient versus node number in hidden layer




图 5 均方误差随神经网络结构的变化图

Fig. 5 RMSE variety versus node number in hidden layer

经过大量试算,并对图 4 和图 5 的结果进行比较分析,发现在隐含层的节点数为 6,并且输入层采用 NDVI 和 SAVI 时,运算结果与植被覆盖度的相

关系数最大,并且均方误差最小。因而,最终确定的神经网络结构为图 6 所示的比较简单三层结构。第一层神经元传递函数选用 Tansig 函数,第二层采用 Purelin 函数。




图 6 本文 BP 神经网络模型结构图

Fig. 6 Map of the BP neural network in this paper

神经网络的每个训练样本由输入值和理想输出值两部分组成。当网络的所有实际输出值和理想输出值一致时训练结束,否则,通过修改权重,使网络的实际输出值和理想输出值一致。BP 神经网络对于训练样本的数量没有明确的要求,但是必须既要保障有足够的样本用于神经网络学习辨识转移函数,又要综合考虑节点数和实际要求。结合实地测量的 30 个样本,即有 30 组数据,随机选取其中的 22 组当作训练样本,然后用余下的 8 组进行神经网络验证。本文中随机选取用作训练的样本点如图 7 中圆点所示,余下的 8 组用作网络验证的样本点如图 7 三角点所示。验证主要是用来评价已经训练好的网络是否具有较好的泛化能力,同时也可用来检验在训练时性能表现良好的网络是否就是所需要的解。经过训练如果输入验证组样本仍能给出在误差范围内可以接受的结果,神经网络就被




图 7 神经网络训练样本点示意图

Fig. 7 Map of training samples and testing samples

认为是训练完毕,可以接受;否则就认为神经网络学习失败,需要重新进行训练验证,直到神经网络被训练到满意为止。

利用图 6 的结构图,在实际操作时,把输入层的值在训练计算时分发到隐含层进行计算;再把隐含层的输出值作为输出层的输入值,输入到输出层中进行计算,最终输出层的输出值将是我们感兴趣的参数值——植被覆盖 F_c 。当网络训练 600 次后,网络均方差稳定在 0.024,网络停止训练。

在 BP 神经网络经过训练并通过验证后,才可以把整个密云水库流域的遥感影像用训练成功的神经网络进行计算。最后得到的利用神经网络方法反演得到的植被覆盖值与实测值之间的相关系数 r 为 0.961,均方根误差 RMSE 为 0.131。以上过程均通过 MATLAB 软件实现。

6 结果和分析

利用 30 组样本点对 BP 神经网络进行训练和验证得到稳定而且理想的结果后,将通过“北京一号”小卫星数据进行处理得到的 NDVI 和 SAVI 图输入到神经网络进行计算。这时,输出的值是利用网络反演得到的整个密云水库流域的植被覆盖值。植被覆盖反演结果和实测结果比较如图 8 所示。




图 8 植被覆盖实测值与 BP 神经网络反演值比较图
Fig.8 Comparison of the measured values and retrieval values

为了对神经网络反演结果进行比较,另外对此 30 个样点的实测数据进行了回归分析,回归分析算法如下式:

$$F_c=0.5305-44.4196 \times \text{NDVI}+29.8908 \times \text{SAVI}$$

(11)

其中: F_c 为植被覆盖值。

为了对结果进行对比分析,另外采用 NDVI 像元二分法^[21,22]进行反演。利用 3 种方法反演得到的相关系数 r 和均方根误差 RMSE 如表 2 所示。

表 2 各种算法精度比较

Table 2 Accuracy comparison of various algorithms

参数	BP 神经网络法	回归分析法	NDVI 像元二分法
相关系数 r	0.921	0.425	0.870
均方根误差 RMSE	0.024	0.117	0.06

从表 2 可以看出,回归分析法计算得到的结果比较差,这表明在密云水库流域利用统计回归分析对于描述植被覆盖值和图像辐射亮度值之间的关系是不理想的,但是 BP 神经网络的表现和 NDVI 像元二分法的表现还是令人满意的。在水库流域,传感器接收到的植被信息会受到山区地形等多种成分非线性方式的影响,而且在山体背阴处,其值还会进一步受到山体阴影的影响。目前,山区植被遥感信息处理的主要难点在于问题的非线性和被反演物质光学性质特征之间的类似性。对经验统计算法进行分析,发现其表现较差的原因应该是由于采样点数量的不足、分布不均匀、大气校正算法不够精确、采样点位置与图像上样本点站之间匹配错误以及经验算法的某些常数不完全适用于山区等因素所致;但是,其主要的误差来源是没有对山区植被信息和遥感反射率之间非线性的信息传递机理进行有效的模拟,而这些又恰恰是神经网络的优势所在。由此可见,对山区特别是密云水库流域,需要有比平原地带所开发的算法更为复杂的算法,而神经网络在这方面恰好可以为人们提供一种有效的手段和技术。

图 9 和图 10 分别为本文经过 BP 神经网络方法进行反演最后得到的密云水库流域的植被覆盖图和植被覆盖分级图。图 9 和图 10 中白色部分为水库。首先由反演图可以看到密云水库流域内植被覆盖的情况,密云水库流域内的植被覆盖情况也是东南部高于中部,中部又高于西北部,植被覆盖最高的几个地方即图中最绿的部分大都集中在流域的北面中部地带、南面中部地带与东南角地区。从图中可以看出,流域内植被覆盖较差的地区即图中红色的地方为潮河,白河和黑河的河床,这也是因为河床地势较低,主要的土地利用类型为耕地,受到季节的影响较大,并且人类活动比较频繁,因此植被覆盖要比中部山区要低一个层次。利用 BP 神经网络反演得到的密云水库流域内的平均植被覆盖值为 57.8%。

7 结 语

通过比较分析可以看出,在山区植被信息遥感反演算法中神经网络方法以其对非线性过程的精确模

拟而具有比传统算法更高的精度,尤其对于遥感反演算法难度较大的山区植被覆盖信息提取效果较好。

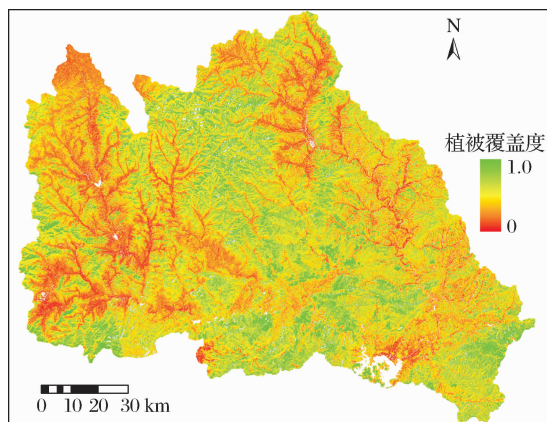


图 9 BP 神经网络法反演研究区植被覆盖图

Fig. 9 Vegetation cover map of the Drainage basin of Miyun Reservoir

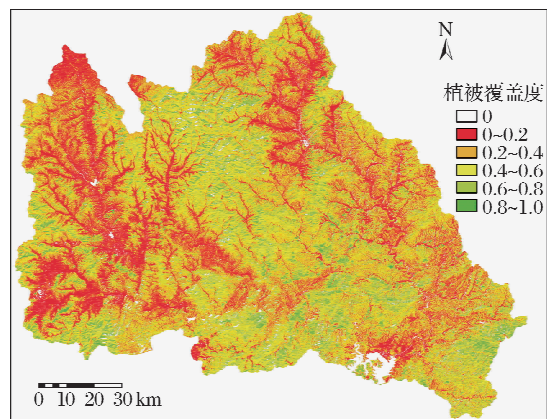


图 10 BP 神经网络法反演研究区植被覆盖分级图

Fig. 10 Graduation map of vegetation cover of the Drainage basin of Miyun Reservoir

山区植被的光学性质受到地形等各种因素及季节变化的影响,这就要对算法考虑地区和季节上的差异,而且对每一种神经网络要利用特定地区或季节有效的光学性质予以训练才能进行有效的反演。尽管进行不同地区不同季节的研究时具体算法的参数可能会有所差别,但用神经网络方法反演山区植被覆盖信息还是普遍适用的。

利用神经网络反演时存在的主要问题是采样数据点较少,这就大大限制了训练样本的选择,虽然神经网络可以选取其余数据作为训练样本输入,但是如果能有分布更加广泛均匀的同步样点数据,获得更多的样点来进行分析,并且利用不同的多时相数据,应该能够获得更加稳定的网络,从而提高神经网络的精度并使之更具普适性。

参考文献:

- [1] Leprieux C, Kerr Y H, Mastorchio S, *et al.* Monitoring Vegetation Cover across Semi-arid Regions, Comparison of Remote Observations from Various Scales[J]. International Journal of Remote Sensing, 2000, 21(2): 281-300.
- [2] Dymond J R, Stephens P R, Newsome P F, *et al.* Percent Vegetation Cover of a Degrading Rangeland from SPOT[J]. International Journal of Remote Sensing, 1992, 13(11): 1999-2007.
- [3] Graetz R D, Pech R R, Davis A W. The Assessment and Monitoring of Sparsely Vegetated Rangelands Using Calibrated Landsat Data[J]. International Journal of Remote Sensing, 1988, 9(7): 1201-1222.
- [4] Purevdorj T S, Tateishi R, Ishiyama T, *et al.* Relationships between Percent Vegetation Cover and Vegetation Indices [J]. International Journal of Remote Sensing, 1998, 19(18): 3519-3535.
- [5] Choudhury B J, Ahmed N U, Idso S B, *et al.* Relations between Evaporation Coefficients and Vegetation Indices Studied by Model Simulations[J]. Remote Sensing of Environment, 1994, 50(1): 1-17.
- [6] Carlson T N, Gillies R R, Perry E M. A Method to Make Use of Thermal Infrared Temperature and NDVI Measurements to Infer Surface Soil Water Content and Fractional Vegetation Cover[J]. Remote Sensing Review, 1994, (9): 161-173.
- [7] Yang Shengtian, Liu Changming, Yang Zhifeng, *et al.* Natural Eco-environmental Evaluation of West Route Area of Interbasin Water Transfer Project [J]. Acta Geographica Sinica, 2002, 57(1): 11-18. [杨胜天, 刘昌明, 杨志峰, 等. 南水北调西线调水工程区的自然生态环境评价[J]. 地理学报, 2002, 57(1): 11-18]
- [8] Thiria S, Mejia C, Badran F, *et al.* A Neural Network Approach for Modelling Non Linear Transfer Functions: Application for Wind Retrieval from Spaceborne Scatterometer Data [J]. Journal of Geophysical Research, 1993, 98(C12): 22827-22841.
- [9] Krasnopolsky V M, Breaker L C, Gemmill W H. A Neural Network as a Nonlinear Transfer Function Model for Retrieving Surface Wind Speeds from the Special Sensor Microwave Imager[J]. Journal of Geophysical Research, 1995, 100(C6): 11033-11045.
- [10] Cong Pifu, Niu Zheng, Wang Xinming, *et al.* Application of Neural Network in Retrieving Chlorophyll a Concentration from SeaWiFS in the Sea Area Near Dalian[C]//IGARSS, 2005a(Korea).
- [11] Weiss M, Baret F. Evaluation of Canopy Biophysical Variable Retrieval Performances from the Accumulation of Large Swath Satellite Data[J]. Remote Sensing of Environment, 1999, 70(3): 293-306.
- [12] Bacour C, Baret F, Béal D, *et al.* Neural Network Estimation of LAI, fAPAR, fCover and LAI×Cab, from Top of Canopy MERIS Reflectance Data: Principles and Validation[J]. Re-

- Remote Sensing of Environment, 2006, 105(4): 313-325.
- [13] Abuelgasim A A, Gopal S S, Trahler A H. Forward and Inverse Modelling of Canopy Directional Reflectance Using a Neural Network[J]. International Journal of Remote Sensing, 1998, 19(3): 453-471.
- [14] Mark D F, Craig P S, Man W, *et al.* Landscape Dynamics and Risk Modeling of Human Alveolar Echinococcosis[J]. Photogrammetric Engineering and Remote Sensing, 2003, 24(23): 4891-4905.
- [15] Fang H, Liang S. A Hybrid Inversion Method for Mapping Leaf Area Index from MODIS Data: Experiments and Application to Broadleaf and Needleleaf Canopies[J]. Remote Sensing of Environment, 2005, 94(3): 405-424.
- [16] Smith J A. LAI Inversion Using a Back-propagation Neural Network Trained with a Multiple Scattering Model[J]. IEEE Transactions on Geoscience and Remote Sensing, 1993, 31(5): 1102-1106.
- [17] Feng Tianjin. The Technique of Neural Networks[M]. Qingdao: Qingdao Oceanography University Publishing Company, 1994. [冯天瑾. 神经网络技术[M]. 青岛: 青岛海洋大学出版社, 1994.]
- [18] Jiang Dong, Wang Jianhua. The Development and Application of Artificial Neural Network Technique in Remote Sensing [J]. Remote Sensing for Land & Resources, 1999, 42: 12-17. [江东, 王建华. 人工神经网络在遥感中的发展与应用[J]. 国土资源遥感, 1999, 42: 12-17.]
- [19] Cybenko G. Approximations by Superpositions of a Sigmoidal Function[J]. Math Control Signal System, 1989, 2(4): 303-314.
- [20] Robert Hecht-Nielsen. Theory of the Backpropagation Neural Network[C]//International Joint Conference on Neural Networks(IJCNN), 1989, 1: 593-605.
- [21] Li Miaomiao, Wu Bingfang, Yan Changzhen, *et al.* Estimation of Vegetation Fraction in the Upper Basin of Miyun Reservoir by Remote Sensing[J]. Resources Science, 2004, 26(4): 153-159. [李苗苗, 吴炳方, 颜长珍, 等. 密云水库上游植被覆盖度的遥感估算[J]. 资源科学, 2004, 26(4): 153-159.]
- [22] Chen Tao, Li Pingxiang, Zhang Liangpei. Dynamic Analysis of Vegetation Fraction Change in Wuhan Region from 1988 to 2002[J]. Remote Sensing Technology and Application, 2008, 23(5): 511-516. [陈涛, 李平湘, 张良培. 武汉地区 1988-2002 年植被覆盖度变化动态分析[J]. 遥感技术与应用, 2008, 23(5): 511-516.]

An Artificial Neural Network Method for Vegetation Cover Retrieval with “Beijing-1” Microsatellite Data

CHEN Tao^{1,2}, NIU Rui-qing¹, LI Ping-xiang³, ZHANG Liang-pei³

(1. Institute of Geophysics and Geomatics, China University of Geosciences, Wuhan, 430074, China;

2. Key Laboratory of Agrometeorological Safeguard and Applied Technique,

CMA, Zhengzhou, 450003, China; 3. State Key Laboratory of Information Engineering in Surveying, Mapping & Remote Sensing, Wuhan University, Wuhan 430079, China)

Abstract: “Beijing-1” is a new type of earth observation satellite which is launched by China. An Artificial Neural Network (ANN) method for vegetation cover retrieval with “Beijing-1” in Miyun Reservoir basin has been developed in this paper, and then the result was compared with the traditional regression analysis method and the NDVI method for dimidiate pixel model. It demonstrates that for vegetation cover retrieval in mountainous areas, ANN has the advantage of precise simulation of non-linear transmission over traditional methods, especially for case mountainous vegetation information which traditional methods usually fail.

Key words: Vegetation cover; BP neural network; “Beijing-1”; Remote sensing retrieval; Miyun Reservoir basin