

基于 BP 神经网络的淤地坝次降雨泥沙淤积预测

管新建^{1,2},李占斌¹,李 勉³,魏 霞¹

(1 西安理工大学 水利水电学院,陕西 西安 710048;2 郑州大学 环境与水利学院,河南 郑州 450002;
3 黄河水利科学研究院 水土保持研究所,河南 郑州 450003)

[摘 要] 为了探求淤地坝在次降雨情况下的泥沙淤积量,以黄土高原丘陵区花梁坝实测数据为例,引用 3 层前馈型 BP 网络建模方法,对侵蚀性降雨条件下淤地坝泥沙淤积量进行了研究。在模型输入层变量分别为最大 30 min 降雨强度(mm/min)、降雨总量(mm)、平均降雨强度(mm/min)和降雨侵蚀力($\text{mm}^2 \cdot \text{min}$),输出层变量为淤地坝泥沙淤积量,根据降雨资料和淤积信息对应关系所计算的资料,对网络进行了训练,并运用训练后的网络进行模拟和预测。结果表明,BP 网络的绝对拟合误差和相对拟合误差均较低,绝对拟合误差最大为 - 0.006 1 万 t,相对拟合误差最大为 - 1.2946 %。同时,BP 网络还具有较高的预测精度,泥沙淤积预测的绝对误差最大为 - 0.039 万 t,相对误差最大为 - 5.5901 %。该模型的建立为土壤侵蚀产沙规律的研究提供了一条新途径。

[关键词] 淤地坝;泥沙淤积量;BP 神经网络;花梁坝

[中图分类号] TV149

[文献标识码] A

[文章编号] 1671-9387(2007)09-0221-05

Sediment deposition prediction of warping dam in single event rainfall based on BP neural network

GUAN Xin-jian^{1,2},LI Zhan-bin¹,LI Mian³,WEI Xia¹

(1 School of Water Conservancy and Hydropower, Xi'an University of Technology, Xi'an, Shaanxi 710048, China;

2 School of Environment and Water Conservancy, Zhengzhou University, Zhengzhou, He'nan 450002, China;

3 Soil and Water Conservation Institute, Hydraulic Institute of Yellow River Scientific Research, Zhengzhou, He'nan 450003, China)

Abstract : In order to find sediment deposition of warping dam in single event rainfall, sediment deposition under erosive rainfalls was studied with Hualiang warping dam at the hilly and gully regions of the Loess Plateau as example by using BP network of three layers. The input variables of BP network were the maximum rainfall intensity in thirty minutes, the total rainfalls, the mean rainfall intensity, and rainfall erosivity; the output variable was sediment deposition. BP network was trained based on the real data calculated by using rainfall and deposition data. Sediment deposition was simulated and predicted by the trained BP network. Results show that sediment deposition simulation error is low. The maximum absolute simulation error is - 0.0061 (10^4 t); the maximum relative simulation error is - 1.2946 %; at the same time, sediment deposition prediction error is low too. The maximum absolute prediction error is - 0.039 (10^4 t); the maximum relative prediction error is - 5.5901 %. The establishment of BP neural network model provides a new way to study soil erosion and sediment yield rules.

Key words : warping dam; sediment deposition; BP neural network; Hualiang dam

黄土高原是中华民族灿烂文化的发祥地,但水土流失是该区最大的环境问题,能否在黄土高原地

收稿日期] 2006-08-28

[基金项目] 国家自然科学基金项目(50479066)

[作者简介] 管新建(1973-),男,河南确山人,讲师,在职博士,主要从事水土保持及水资源研究。

区有效地控制水土流失,是根治黄河水患的关键。淤地坝是黄土高原地区一种行之有效的既能拦截泥沙,保持水土,又能淤地造田的水土保持工程措施^[1-4]。开展淤地坝次降雨泥沙淤积信息的追踪研究,对解决淤地坝坝系达到相对稳定之前存在的水毁隐患具有重要的意义。然而,到目前为止,对淤地坝坝系优化布局、相对稳定性及坝地效益等受到广泛关注,但对淤地坝次降雨淤积过程研究甚少。由于侵蚀性降雨与其所产生的淤地坝泥沙淤积量之间是一个复杂的非线性问题,这就需要寻求一种比较合适的淤地坝泥沙淤积预测模型,来进行泥沙淤积计算。人工神经网络(ANN)中的BP网络模型,具有较强的自学习能力和处理非线性问题能力,近年来已在有关工程领域得到广泛应用^[5-9]。本研究以陕西省榆林市子洲县南部小河口流域的花梁坝为例,引入这一新的定量研究方法,进行坝地次降雨泥沙淤积预测探索,以期对淤地坝水毁问题的研究提供理论基础,同时对黄土高原资料缺乏地区进行流域综合治理的措施配置,评价小流域水土流失综合治理的环境效应具有重要的意义。

1 典型淤地坝流域概况

本研究选择的花梁坝属于陕西省榆林市子洲县南部小河口流域,流域面积 63.5 km²,相对高差 328 m,为黄土丘陵沟壑区第一副区。流域地形支离破碎,梁峁起伏,沟壑纵横,平均沟壑密度为 3.6 km/km²,大于 25°坡地面积约占流域面积的 25.7%。流域多年平均降水量为 421 mm,多年平均侵蚀模数为 15 000 t/(km²·a),年均输沙量 92.25 万 t。流域土壤主要为黄绵土、粉质壤土、红胶土和淤积土,其中以黄绵土为主,约占流域总面积的 70%左右,土壤胶结差,遇水易溶解,抗蚀性差,有机质含量在 5 g/kg 左右,养分缺乏,呈碱性。其次为粉质壤土,占 15%左右,红胶土和淤积土零星分布于流域的沟壑和淤地坝中。

2 侵蚀性降雨与泥沙淤积量响应关系

影响流域产沙的主要因素有气候因素、地质地貌条件和人类活动方式,对于不同地区的小流域,因其下垫面、气候状况、人类活动方式等因素不同,其产沙特性和产沙机理有很大差异:有的是在缓和外营力长期塑造地貌过程中产生的渐变型产沙;有的则是在剧烈变化中短时间内产生的突变型产沙。本研究所取的典型小流域属于渐变型产沙,气候因素

和下垫面因素是影响其产沙的主要因素。由于该流域在所选择的时间尺度内,没有大规模的人为治理和开发活动。因此,可将流域的下垫面视为不变量,气候因素就成为流域产沙的主要影响因素,而在气候因素中,降雨因素是流域侵蚀产沙最重要的影响因素。本研究根据所收集到的资料情况,选择降雨因素中的最大 30 min 降雨强度(mm/min)、降雨总量(mm)、平均降雨强度(mm/min)、降雨侵蚀力(mm²·min)作为流域产沙的主要影响因子。根据收集到的小河口流域曹坪站 1973~1986 年的降雨资料和淤积信息,按照侵蚀性降雨标准以及大雨对大沙的原则对降雨进行筛选,按时间及泥沙淤积的先后顺序将筛选出的降雨和淤积层数一一对应进行处理,然后根据淤地坝的库容曲线及淤积信息,对不同场次下的降雨侵蚀产沙量进行了计算,求出每个淤积层对应的淤积泥沙量。根据以上思路,得出花梁坝的次降雨资料和淤积信息见表 1。

3 BP 网络及快速 BP 学习算法

BP 网络具有很强的非线性映射及自学习能力,可以广泛应用于函数逼近、模式识别、分类和数据压缩。其构造是一单向传播的多层前向网络,学习算法包括正向计算和误差反向传播两个过程。有关神经网络模型的结构及学习算法可参考文献[10-11]。BP 算法是一种简单的最速下降静态寻优算法,权值调节采用负梯度下降法,这种调节权值的方法有其局限性,即存在收敛速度慢和容易陷入局部极小点等缺点。在实际应用中,原始的 BP 算法很难胜任,因此出现了很多的改进算法,如:模拟退火算法、单纯形法、Tabusearch 算法及遗传算法等。本研究仅介绍优化的快速 BP 算法。

快速 BP 算法采用附加动量法和自适应学习率两种策略,从而避免了陷入局部极小值并加快了网络的训练速度。动量法降低了网络对于误差曲面局部细节的敏感性,有效地抑制了网络陷于局部极小^[12]。该方法是在反向传播的基础上,在每一个权值的变化上加上一项正比于前次权值变化量的值,并根据反向传播法来产生新的权值变化。带有附加动量因子的权值调节公式为:

$$\Delta V_{jt}(k+1) = (1 - mc)\eta d_{jt} + mc\Delta V_{jt}(k), \\ (j = 1, 2, \dots, l; t = 1, 2, \dots, n); \quad (1)$$

$$\Delta V_{1t}(k+1) = (1 - mc)\eta d_{1t} + mc\Delta V_{1t}(k), \\ (t = 1, 2, \dots, n); \quad (2)$$

$$\Delta W_{ij}(k+1) = (1 - mc)\eta E_j x_{jp} + mc\Delta W_{ij}(k),$$

$$(i = 1, 2, \dots, m; j = 1, 2, \dots, l); \quad (3)$$
$$\Delta Q1_j(k+1) = (1 - mc)\eta E_j + m\Delta Q1_j(k), \quad (j = 1, 2, \dots, l)。$$

式中,Δ 为增量, W_{ij} 和 V_{jt} 分别表示输入层到隐含层、隐含层到输出层的连接权值, k 为训练次数, mc 为动量因子, η 为学习速率, d_t 为输出层第 t 神经

元的一般化误差, b_j 为隐含层第 j 神经元输出, l 为隐含层神经元个数, n 为输出层神经元个数, $Q1_j$ 和 $V1_t$ 分别表示隐含层、输出层神经元的阈值, E_j 为隐含层第 j 神经元的一般化误差, x_{ip} 为第 p 个学习样本, m 为输入层神经元个数。

表 1 花梁坝次降雨与相应的淤积信息

Table 1 Corresponding results of Hualiang dam between a single event rainfall and depth of deposition layer

淤积年份 Deposition year	最大 30min 降雨 强度/(mm·min ⁻¹) Maximum rainfall intensity in 30 minutes	降雨总量/mm Total rainfall	平均降雨强度/ (mm·min ⁻¹) Average rainfall intensity	降雨侵蚀力/ (mm ² ·min) Rainfall erosivity	淤积泥沙量/万 t Deposition sediment amount	淤积层厚度/m Depth of deposition layer	淤积层数 Number of deposition layer
1973	0.295	16.90	0.121	4.981	0.343	0.1	1
1973	0.255	30.60	0.042	7.803	0.584	0.16	2
1974	0.331	29.00	0.105	9.606	0.241	0.065	3
1974	0.455	77.10	0.232	35.059	2.070	0.86	4
1975	0.400	18.60	0.067	7.440	0.419	0.1	5
1976	0.396	18.70	0.328	7.400	0.307	0.08	6
1977	0.610	82.20	0.182	50.142	3.081	0.88	7
1977	0.534	29.00	0.261	15.487	0.889	0.21	8
1978	0.347	98.20	0.132	34.043	1.424	0.39	9
1978	0.714	20.00	0.714	14.286	0.655	0.16	10
1978	0.252	31.60	0.075	7.953	0.448	0.09	11
1978	0.444	36.10	0.146	16.019	0.556	0.15	12
1978	0.335	51.20	0.098	17.152	0.889	0.19	13
1979	0.447	31.30	0.079	13.998	0.569	0.14	14
1979	0.328	30.40	0.290	9.979	0.560	0.15	15
1979	0.205	77.90	0.068	15.970	0.442	0.08	16
1980	0.210	30.60	0.082	6.426	0.283	0.07	17
1980	0.305	23.20	0.107	7.076	0.520	0.13	18
1980	0.588	15.40	0.068	9.048	0.595	0.12	19
1980	0.247	21.20	0.077	5.238	0.119	0.03	20
1981	0.300	87.90	0.047	26.370	0.891	0.18	21
1981	0.307	21.10	0.141	6.483	0.511	0.13	22
1982	0.405	95.20	0.115	38.556	2.348	0.56	23
1986	0.427	27.20	0.302	11.605	0.483	0.11	24

根据附加动量因子的设计原则,当修正的权值在误差中导致太大的增长结果时,新的权值应被取消而不被采用,并使动量作用停下来,以使网络不进入较大误差曲面;当新的误差变化率对其旧值超过一个事先设定的最大误差变化率时,也应取消所计算的权值变化。其最大误差变化率可以是任何大于或等于 1 的值,典型的值取 1.04^[13]。训练程序中采用动量法的判断条件为:

$$mc = \begin{cases} 0, SSE(k) > SSE(k-1) \cdot 1.04; \\ 0.95, SSE(k) < SSE(k-1); \\ mc, \text{其他。} \end{cases} \quad (5)$$

式中, SSE 为误差平方和。

对于一个特定的问题,要选择适当的学习速率并不是一件容易的事情。通常是凭经验或试验获得,但即使这样,对训练初期功效较好的学习速率,

不一定对后来的训练合适。为了解决这个问题,可以在训练过程中自动调整学习速率。自适应学习速率的调整公式为^[5]:

$$\eta(k+1) = \begin{cases} 1.05\eta(k), SSE(k+1) < SSE(k); \\ 0.7\eta(k), SSE(k+1) > 1.04 \cdot SSE(k); \\ \eta(k), \text{其他。} \end{cases} \quad (6)$$

初始学习速率 $\eta(0)$ 的选取范围有很大的随意性。

4 花梁坝坝控流域次降雨泥沙淤积量预测的 BP 神经网络模型

4.1 网络结构的选择

4.1.1 输入变量的选择 输入变量的选择采用了影响流域侵蚀产沙的 4 个主要因素,即最大 30 min 降雨强度 (mm/min)、降雨总量 (mm)、平均降雨强

度 (mm/min)、降雨侵蚀力 (mm²·min)。

4.1.2 隐含层数及隐含层神经元数的确定 在对隐含层数及隐含层神经元数的确定中,考虑到流域侵蚀产沙预测是个较为复杂的非线性问题,既要满足精度要求,又要尽可能减少学习时间,则选择 1 个隐含层足够了。试算发现,隐含层神经元数为 21 时网络收敛较好。

4.1.3 输出层神经元数 输出层神经元数为 1,对应于所要预测的泥沙淤积量。

综上所述,花梁坝坝控流域次降雨泥沙淤积量预测的 BP 神经网络结构为 4-21-1。

4.2 训练样本的选取

根据 1973~1986 年花梁坝所采集到的 24 场降雨及泥沙淤积量资料,首先对前 20 个样本进行学习,然后用训练好的网络预测后 4 次降雨的泥沙淤积量。

4.3 输入和输出数据的预处理

神经网络学习前的数据预处理,对网络有至关

重要的影响。上述 4 个结构变量在数值上的变化相差较大,另外其量纲也不尽相同,故不能直接用于神经网络的训练,否则会严重影响网络的学习速度及网络的精度等。因此,本研究先对输入和输出数据进行预处理,即有:

$$x'_j = \frac{x_j}{x_{jmax} + x_{jmin}}, \tag{7}$$

$$y'_j = \frac{y_j}{y_{jmax} + y_{jmin}}. \tag{8}$$

式中, x_{jmax} 、 x_{jmin} 分别表示第 j 个影响因子 x_j 在 20 组训练样本中的最大值与最小值, x'_j 表示预处理之后的影响因子值, y_{jmax} 、 y_{jmin} 分别表示第 j 个输出变量 y_j 在 20 组训练样本中的最大值与最小值, y'_j 表示预处理之后的输出变量值。

经过上述处理后,4 个输入变量和 1 个输出变量的值均变换到 (0,1) 内,并将其作为网络的输入值和输出值(表 2)。

表 2 花梁坝次降雨与淤积信息预处理后的输入变量和输出变量值

Table 2 Input and output variable values of preliminary treatment to a single event rainfall and deposition information of Hualiang dam

淤积年份 Deposition year	最大 30min 降雨强度 Maximum rainfall intensity in 30 minutes	降雨总量 Total rainfall	平均降雨强度 Average rainfall intensity	降雨侵蚀力 Rainfall erosivity	淤积泥沙量 Deposition sediment amount	淤积层厚度 Depth of deposition layer	淤积层数 Number of deposition layer
1973	0.321 0	0.148 8	0.160 1	0.090 4	0.107 2	0.10	1
1973	0.277 5	0.269 4	0.055 6	0.141 6	0.182 5	0.16	2
1974	0.360 2	0.255 3	0.138 9	0.174 3	0.075 3	0.065	3
1974	0.495 1	0.678 7	0.306 9	0.636 0	0.646 9	0.86	4
1975	0.435 3	0.163 7	0.088 6	0.135 0	0.130 9	0.10	5
1976	0.430 9	0.164 6	0.433 9	0.134 2	0.095 9	0.08	6
1977	0.663 8	0.723 6	0.240 7	0.909 6	0.962 8	0.88	7
1977	0.581 1	0.255 3	0.345 2	0.281 0	0.277 8	0.21	8
1978	0.377 6	0.864 4	0.174 6	0.617 6	0.445 0	0.39	9
1978	0.776 9	0.176 1	0.944 4	0.259 2	0.204 7	0.16	10
1978	0.274 2	0.278 2	0.099 2	0.144 3	0.140 0	0.09	11
1978	0.483 1	0.317 8	0.193 1	0.290 6	0.173 8	0.15	12
1978	0.364 5	0.450 7	0.129 6	0.311 2	0.277 8	0.19	13
1979	0.486 4	0.275 5	0.104 5	0.253 9	0.177 8	0.14	14
1979	0.356 9	0.267 6	0.383 6	0.181 0	0.175 0	0.15	15
1979	0.223 1	0.685 7	0.089 9	0.289 7	0.138 1	0.08	16
1980	0.228 5	0.269 4	0.108 5	0.116 6	0.088 4	0.07	17
1980	0.331 9	0.204 2	0.141 5	0.128 4	0.162 5	0.13	18
1980	0.639 8	0.135 6	0.089 9	0.164 1	0.185 9	0.12	19
1980	0.268 8	0.186 6	0.101 9	0.095 0	0.037 2	0.03	20

4.4 初始参数的选择及网络的训练

采用快速 BP 算法训练网络时,设定显示间隔次数为 20;最大循环次数为 1×10^6 ;目标误差为 1×10^{-4} ;初始学习速率为 0.01;学习速率增加的比率为 1.05;学习速率减小的比率为 0.7;动量常数为 0.9;最大误差比率为 0.7。

将表 2 中预处理后的 20 个学习样本依次输入 BP 网络,按上述快速 BP 学习算法的步骤反复训练,在训练了 57 443 次后,其均方误差 $SSE < 1 \times 10^{-4}$,结束训练,并输出此时经调整后的各层之间的联结权值和各层阈值(略),用输出后的权值和阈值对前 20 次降雨的泥沙淤积量进行模拟,结果见表 3,并对后 4 次

降雨的泥沙淤积量进行预测,结果见表 4。

由表 3 和表 4 可知,BP 网络的绝对拟合误差和相对拟合误差均较低,而且 BP 网络还具有较高的预测精度。其原因在于次降雨侵蚀产沙与有限的几个影响因素之间是一种非线性、不确定性关系,而 BP 网络所描述的输入输出正是一种非线性、不确定性关系,用其预测淤地坝泥沙淤积量在一定程度上反映了客观实际,故具有较高的拟合和预测精度。

表 3 花梁坝次降雨泥沙淤积量的模拟结果

Table 3 Simulation results of sediment deposition of Hualiang dam in a single event of rainfall									
淤积年份 Deposition year	实际值/ 万 t Real value	模拟值/ 万 t Simulation value	绝对误差/ 万 t Absolute error	相对误差/ % Relative error	淤积年份 Deposition year	实际值/ 万 t Real value	模拟值/ 万 t Simulation value	绝对误差/ 万 t Absolute error	相对误差/ % Relative error
1973	0.343	0.340 8	- 0.002 2	- 0.641 4	1978	0.448	0.442 2	- 0.005 8	- 1.294 6
1973	0.584	0.586 7	0.002 7	0.462 3	1978	0.556	0.549 9	- 0.006 1	- 1.097 1
1974	0.241	0.242 4	0.001 4	0.580 9	1978	0.889	0.888 9	- 0.000 1	- 0.011 2
1974	2.070	2.067 8	- 0.002 2	- 0.106 3	1979	0.569	0.566 5	- 0.002 5	- 0.439 4
1975	0.419	0.419 5	0.000 5	0.119 3	1979	0.560	0.560 7	0.000 7	0.125 0
1976	0.307	0.303 8	- 0.003 2	- 1.042 3	1979	0.442	0.441 8	- 0.000 2	- 0.045 2
1977	3.081	3.080 8	- 0.000 2	- 0.006 5	1980	0.283	0.285 7	0.002 7	0.954 1
1977	0.889	0.893 3	0.004 3	0.483 7	1980	0.520	0.516 4	- 0.003 6	- 0.692 3
1978	1.424	1.422 7	- 0.001 3	- 0.091 3	1980	0.595	0.594 6	- 0.000 4	- 0.067 2
1978	0.655	0.655 0	0.000 0	0.000 0	1980	0.119	0.119 0	0.000 0	0.000 0

表 4 花梁坝次降雨泥沙淤积量的预测结果

Table 4 Prediction results of sediment deposition of Hualiang dam in a single event of rainfall				
淤积年份 Deposition year	实际值/ 万 t Real value	预测值/ 万 t Prediction value	绝对误差/ 万 t Absolute error	相对误差/ % Relative error
1981	0.891	0.912	0.021 0	2.356 9
1981	0.511	0.520	0.009 0	1.761 3
1982	2.348	2.309	- 0.039 0	- 1.661 0
1986	0.483	0.456	- 0.027 0	- 5.590 1

5 结 语

由于侵蚀性降雨与其所产生的淤地坝泥沙淤积量之间是一个复杂的非线性问题,人工神经网络是处理非线性问题的有效方法。因此,本研究将 BP 神经网络用于陕西省榆林市子洲县南部小河流流域的花梁坝泥沙淤积预测,得出如下初步结论:

(1) 利用淤地坝泥沙淤积的 BP 网络模型,预测不同场次降雨下泥沙淤积量,效果较好。模型输入变量中,最大 30 min 降雨强度(mm/min)、降雨总量(mm)、平均降雨强度(mm/min)、降雨侵蚀力(mm²·min),比较容易测定,模型便于利用,与传统回归模型相比较,该模型能更好地刻画坝控流域侵蚀产沙的复杂非线性特性,为土壤侵蚀产沙规律的研究提供了新方法。

(2) 该 BP 网络模型的输入参数,是在一定条件下建立的,具有一定的使用范围,影响坝控流域侵蚀产沙的因素众多,如人为活动、下垫面特性以及植被等因素,均会影响到坝控流域的侵蚀产沙,在今后研

究中仍需深入探讨。

【参考文献】

[1] 焦菊英,王万忠,李靖,等.黄土高原丘陵沟壑区淤地坝的淤地拦沙效益分析[J].农业工程学报,2003,19(6):302-306.

[2] 方学敏,万兆惠,匡尚富.黄河中游淤地坝拦沙机理及作用[J].水利学报,1998(10):49-53.

[3] 胡建军,牛萍,曹炜.浅谈黄河上中游地区水土保持淤地坝工程的作用[J].西北水资源与水工程,2002,13(2):28-31.

[4] 李敏.淤地坝在黄河中游水土流失防治中的作用[J].人民黄河,2003,25(12):25-27.

[5] Dawson C W,Wilby R. An artificial neural network approach to rainfall-runoff modeling[J]. Hydrol Sci J,1998,43(1):47-66.

[6] French M N,Krajewski W F,Cuykendall R R. Rainfall forecasting in space and time using a neural network[J].J Hydrol,1992,137:1-37.

[7] Wen C G,Lee C S. A neural network approach to multi objective optimization for water quality management in a riverbasin[J]. Water Resour Res,1998,34(3):427-436.

[8] 尚松浩,毛晓敏,雷志栋,等.冬小麦田间墒情预报的 BP 神经网络模型[J].水利学报,2002(4):60-63.

[9] 彭清娥,刘兴年,曹叔尤,等.流域平均含沙量的人工神经网络模型[J].水利学报,2000(11):79-83.

[10] 赵西宁,吴普特,冯浩,等.基于人工神经网络的坡面土壤侵蚀研究[J].中国水土保持科学,2004,2(3):31-35.

[11] 吴泽宁,索丽生,左其亭.水利水电工程人工神经网络综合优选模型[J].水利水电技术,2001,32(7):6-8.

[12] 李方明,陈国兴.基于 BP 神经网络的饱和砂土液化判别方法[J].自然灾害学报,2005,14(2):108-114.

[13] 丛爽.面向 MATLAB 工具箱的神经网络理论与应用[M].合肥:中国科学技术大学出版社,1998.