

基于 Elman 动态神经网络的土壤墒情预测研究

邵月红¹, 刘永和²

(1. 南京信息工程大学 应用水文气象研究院, 江苏 南京 210044; 2. 河南理工大学 资源环境学院, 河南 焦作 454000)

摘要: 土壤墒情是一个非线性、时空异质性和动态不确定过程, 利用 Elman 动态神经网络对研究区临沂站和平邑站土壤水分含量进行了预测。结果表明, 所建立的网络模型能够对土壤墒情进行成功模拟, 预测的土壤水分值与观测值吻合得较好, 模拟精度较高。临沂站和平邑站模拟土壤墒情的平均绝对误差分别为 1.08% 和 1.07%, 平均相对误差为 10.2% 和 11.0%。Elman 动态神经网络模型利用其独特的非线性、非凸性和适应时变特性的能力从时空变率复杂的土壤水分运移系统中找出一定的演变规律, 为土壤水分预测提供了一种有效可靠的方法。为了更好地验证该方法的优越性, 还需要更多的样本数据, 更多的区域和更全面的敏感影响因素来验证, 以及更深层次的理论研究和分析。

关键词: Elman 神经网络; 土壤; 墒情预测

文献标识码: B

文章编号: 1000-288X(2012)05-0257-04

中图分类号: S157, TP18

Soil Moisture Prediction Based on Elman Recurrent Dynamic Neural Networks Model

SHAO Yue-hong¹, LIU Yong-he²

(1. Applied Hydrometeorological Research Institute, Nanjing University of Information Science and Technology, Nanjing, Jiangsu 210044, China; 2. Institute of Resources and Environment, He'nan Polytechnic University, Jiaozuo, He'nan 454000, China)

Abstract: By considering the nonlinearity, spatial and temporal heterogeneity and dynamic uncertainty of soil moisture process, Elman recurrent neural network model is applied to the prediction of soil moisture in Linyi and Pingyi stations. Results show that the model achieves a high accuracy of soil moisture simulation and the simulated values agree well with observed values in the whole process. The mean absolute errors of prediction precision for Linyi and Pingyi stations are 1.08% and 1.07%, and the mean relative errors, 10.2% and 11.0%, respectively. Elman recurrent neural network model can be used to find some evolutionary characters and regular patterns from complex soil moisture system by taking advantage of its nonlinearity, non-appendage and self-adaption capacity. Therefore, the model provides a simple and efficient method which provides high accuracy and reliable precision for soil moisture simulation. In order to further evaluate the superiority of this method, a longer series of data, more investigations in other regions and more comprehensive influence factors are needed to deepen theoretical study and analysis because of limited samples and the highly dynamic uncertainty of soil moisture process.

Keywords: Elman neural network; soil; moisture prediction

农田土壤水分预测是农田水分平衡及土壤—植物—大气连续体研究的重点。研究土壤水分预测, 对于充分利用农业气候资源、干旱评估、测产估产等具有十分重要的意义。常用的土壤墒情预测模型有经验公式法^[1-2]、水量平衡法^[3]、土壤水动力学法^[4-5]和时间序列模型法^[6]等, 当条件具备时, 可以获得比较满意的结果。

然而, 以上方法在实际应用中存在以下问题: (1) 需要通过试验测定或通过统计分析得到符合条件的各种参数, 由于自然条件时空变异性, 模型的实际推广受到限制; (2) 传统水分预测模型需要输入的参数基本上是确定的, 如果缺少其中的部分输入量, 将严重影响模型的预测结果, 而实际应用中, 多数参数很难获得, 使模型难以应用。多年来, 土壤水分预测

收稿日期: 2011-01-17

修回日期: 2011-11-28

资助项目: 水利部公益性行业专项“水文气象分区线性矩法在防洪规划中的应用”(201001047); 南京信息工程大学科研基金项目“雷达定量估测降水在洪水预报中的应用研究”(20100402); 国家青年科学基金项目“基于广义非线性模型和天气预报资料的降水统计降尺度模型优选研究”(41105074); 江苏高校优势学科建设工程资助项目(PAPD)

作者简介: 邵月红(1977—), 女(汉族), 山西省侯马市人, 博士, 讲师, 主要从事水文、水资源、GIS 与 RS 的研究。E-mail: syh@nuist.edu.cn。

主要凭经验, 缺乏准确性、科学性和时效性, 因此, 寻求一种理论坚实、操作简单快速、又能满足实际需要的模型是提高土壤水分预测的有效途径。

人工神经网络模型以其独特的非线性、非凸性、自适应性等许多复杂的非线性领域中得到成功的应用。土壤墒情是一个高度非线性、受多因素影响的动态不确定过程。因此, 神经网络在土壤水分预测中得到了广泛地应用^[7-8]。目前, 多采用静态的 BP 神经网络进行土壤水分预测, 但是这种结构随着系统阶次的增加, 使网络学习的收敛速度减慢, 造成网络输入结点过多、训练困难等弊病^[9]。Elman 神经网络 (Elman neural network, ENN) 作为一种典型的动态回归神经网络, 它在前馈网络的基础上, 通过存储内部状态使其具备映射动态特征的功能, 从而使得系统具有适应时变特性的能力^[10]。因此, 本文以山东省临沂和平邑 2 个测墒站为研究区, 在研究土壤墒情与气候因素关系的基础上, 利用历史实测土壤墒情资料, 采用 ENN 对土壤墒情变化进行了深入的研究, 并对其预测精度进行了评估。

1 材料与方法

1.1 流域概况及资料情况

研究区域为山东省临沂和平邑测墒站, 属于典型的暖温带大陆性季风气候, 冬季寒冷多风, 降水稀少, 夏季炎热多雨, 春秋两季气候温和。据多年资料统计, 流域内多年平均气温 14.1 °C, 蒸发量 839 mm, 降水量 849 mm, 年降水量主要集中在夏季, 暴雨多而强度大, 全年无霜期 200 d 以上。地下水埋藏深度随季节而变化, 一般在 4.0 m 左右。土壤类型为棕壤, 作物类型为麦田。研究区数据来源于 TDR 土壤水分检测系统。

本研究收集了临沂站和平邑站的 2001—2006 年土壤墒情数据, 即每年的 2—12 月的上旬的 8 日、中旬的 18 日和下旬的 28 日的的数据。其中临沂站 2005 年和 2006 年的 12 月中旬和下旬的数据缺测, 平邑站 2001—2006 年的 2 月上旬、中旬, 12 月的上中下旬, 2001 和 2003 年的 7 月和 8 月的上中下旬数据缺测。本文将 2001—2004 年的数据作为训练样本, 2005—2006 年的数据作为检验样本来验证模型的模拟能力和可扩展性能。

1.2 Elman 动态神经网络模型介绍

ENN 是 Elman 于 1990 年提出的一种局部递归的神经网络^[11], 其基本思想是利用最小二乘法, 采用梯度搜索技术实现网络的实际输出与期望输出的均方差最小化^[12]。主要结构包括 4 层: 输入层、隐含

层、承接层和输出层。输入层单元起信号传输作用, 输出层单元起线性加权作用, 隐含层单元的传递函数可采用线性或非线性函数, 承接层用来记忆隐含层单元前一时刻的输出值, 可以认为是一个一步延时算子。因此, ENN 最大的优点是其有“记忆”能力, 隐含层的输出通过承接层的延迟与存储, 自联到隐含层的输入, 使其对历史状态的数据具有敏感性, 内部反馈网络的加入增加了网络本身处理动态信息的能力, 从而达到了动态建模的目的, 使系统能直接反映动态过程系统的特性 (图 1)。

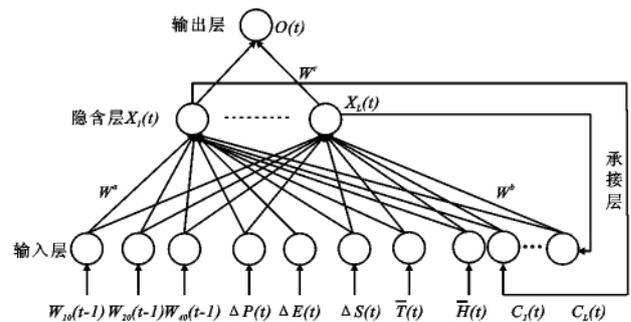


图 1 土壤墒情预测的 Elman 神经网络结构

注: $I(t) = [W_{10}(t-1), W_{20}(t-1), W_{40}(t-1), \Delta P(t), \Delta E(t), \Delta S(t), \bar{T}(t), \bar{H}(t)]$ 为输入向量, 依次分别表示 10 cm 初墒、20 cm 初墒、40 cm 初墒、墒期降雨量、墒期蒸发量、墒期日照时数、平均气温、平均相对湿度; $O(t)$ 为输出向量, 表示 20 cm 土壤末墒; $X(t) = [X_1(t), X_2(t), \dots, X_L(t)]$ 为隐含层的输出向量; $C(t) = [C_1(t), C_2(t), \dots, C_L(t)]$ 为承接层输出向量; t 为时间步长; W^a, W^b, W^c 分别为输入层到隐含层、承接层到隐含层和隐含层到输出层的权重矩阵。

其学习过程如下:

$$X(t) = f[W^a I(t) + W^b C(t)] \quad (1)$$

$$C(t) = X(t-1) \quad (2)$$

$$O(t) = g[W^c X(t)] \quad (3)$$

其中隐含层的传递函数 $f(\cdot)$ 为某种非线性函数, 本文采用“tansig”函数。输出层的传递函数 $g(\cdot)$ 采用 S 型对数函数“logsig”函数。

ENN 也采用 BP 算法进行权值修正, 使修改后的最终输出接近希望输出。学习指标函数采用误差平方和函数:

$$e_t = \frac{1}{2} \sum_{i=1}^m (D_i - O_i)^2 \quad (4)$$

式中: D_i ——目标输出向量; O_i ——神经网络的实际输出。

2 结果与讨论

2.1 基于 Elman 神经网络的土壤墒情预测

ENN 建立的过程主要包括: 数据的前处理、模型训练样本的选择、输入模式的确定、选择合适的网络

拓扑结构、参数估计和模型检验等。

(1) 数据前处理。数据前处理是 ENN 建模的前期重要工作。由于土壤墒情、降雨、蒸发和气温等参数的变幅范围相差比较大,在神经网络训练中,这样的输入输出不利于模型的收敛,采用下式对建模数据进行归一化处理,规范范围为 $[0, 1, 0.9]$ 。

$$\bar{x}_i = \frac{0.1(x_i - x_{\max}) + 0.9(x_{\min} - x_i)}{x_{\min} - x_{\max}} \quad (5)$$

式中: \bar{x}_i ——归一化后的数据; x_i ——实测值序列; x_{\max} ——实测最大值; x_{\min} ——实测最小值。利用式(5)分别将 10, 20 和 40 cm 的土壤墒情数据,两次墒情期间的阶段总降雨量、总蒸散量和总日照时数,阶段平均气温和平均相对湿度数据进行归一化处理,处理后的数据分成两组,2001—2004 年的一组数据作为训练样本,2005—2006 年的另一组作为检验样本。

(2) 输入、输出层模式的确定。输入层模式的确定是决定 ENN 训练的精度及成功的关键因素。输入分量过多,容易形成过适应;分量过少,难以捕捉复杂的非线性关系。影响土壤墒情的因素比较多,根据水量平衡方程,主要包括降水量(灌水)、蒸发量、径流量、渗漏量(地下水)。假定灌水、径流量、渗漏量为常量,同时由于研究区地下水埋深较深,没有收集到该方面的资料,因此本文未考虑地下水的影响。影响蒸散发的主要气象因子有日照时数、气温和相对湿度。综合考虑各方面的影响,本文的输入模式分量为 10, 20, 和 40 cm 的土壤初墒,两次墒情期间的阶段降雨量、蒸散量和日照时数,阶段平均气温和平均相对湿度数据,输入层节点数为 8 个。考虑到小麦的根系主要分布在 20 cm 左右,因此将阶段末的 20 cm 土壤水分作为网络输出,输出层节点数为 1 个。

(3) 隐含层及其节点的确定。正确选择隐含层节点数是网络成功的关键。实践证明,隐含层节点数

太少时,易陷入局部最小,容错性较差;节点太多时又会使得训练时间过长。目前对于如何选择隐含层单元的多少并没有一套确切的理论依据,多是通过经验数值和公式比较确定的。本文临沂站和平邑站的训练样本分别为 131 个和 100 个,利用下式进行估算:

$$H = [M \times n_x / (n_x + n_z)] \quad (6)$$

式中: H ——隐含层节点数目; M ——训练样本数目; n_x, n_z ——输入和输出层节点数; $[]$ ——取整运算符。因此,本文输入层选定为 8 个,输出层为 1 个节点,计算出隐含层节点数 15 个和 12 个。同时,以试错法按照模型既收敛同时误差又较小的原则来确定隐含层最佳节点数。综合判断,隐含层的节点数为 12 个,最终选择 $[8, 12, 1]$ 网络结构来研究土壤墒情的预测。

(4) 学习效率和训练次数的确定。通过试错法,初始学习速率定为 0.05,根据站点的实际情况,计算目标误差采用 5×10^{-3} ,利用上述训练样本对 ENN 进行训练,训练 20 000 次后,学习误差达到 4.95×10^{-3} 。

2.2 模型估测值与墒情观测值的精度评估

本文通过绝对误差和相对误差来定量评估 ENN 模拟的土壤墒情精度。表 1 为 ENN 预测的土壤墒情结果分析。绝对误差和相对误差反映预测值相对于观测值的偏离程度,它能够客观地反映预测结果的准确性。由表 1 可知,临沂站和平邑站训练样本的平均绝对误差分别为 1.08% 和 1.07%,均方差为 2.43% 和 3.92%,平均相对误差为 10.2% 和 11.0%,其中小于 15% 的占到 93.9% 和 87.0%;检验样本的结果与训练样本相似,精度稍低于训练样本。说明 ENN 能够从时空变率复杂的土壤水分序列中找出一定的演变规律,具有运算效率高,简单高效且精度较高等特点,对研究区的土壤水分动态特性进行成功预测,为土壤水分模拟提供了一种有效可靠的方法。

表 1 Elman 动态神经网络训练和预测误差分析

样本类型	站点	数量	绝对误差/%			相对误差/%				
			平均绝对误差	均方差	最大绝对误差	<5	<10	<15	<20	<30
训练样本	临沂	132	1.08	2.43	4.20	46.6	75.6	93.9	100.0	100
	平邑	100	1.07	3.92	4.20	36.0	71.0	87.0	92.0	100
检验样本	临沂	62	1.88	2.45	5.65	25.8	54.8	79.0	88.7	100
	平邑	56	1.81	2.88	6.24	23.2	41.1	67.9	83.9	100

图 2—3 是临沂站及平邑站训练样本和检验样本 20 cm 土壤水分模拟过程图。由图 2—3 可知,无论是训练样本还是检验样本,ENN 预测的 20 cm 土壤水分值与观测的土壤水分值在整个过程都吻合得较

好,整体趋势一致性很强,说明模型都能够对土壤水分值进行很好的模拟,检验样本的精度稍差于训练样本。由过程线还可知,由于样本的数量不是很多,考虑的影响因素受到资料收集的限制,不能有效涵盖各

类型的土壤墒情变化,在一些极值点(最大和最小土壤水分值)模拟的效果较差,误差相对较大。综合分析上述可知,ENN 模型能够较准确地反映研究区复杂的

非线性土壤水分动态过程,是一种较好神经网络模型,具有良好的发展前景。作为一种有效可靠的方法,用它来进行土壤墒情动态过程预测是可行的。

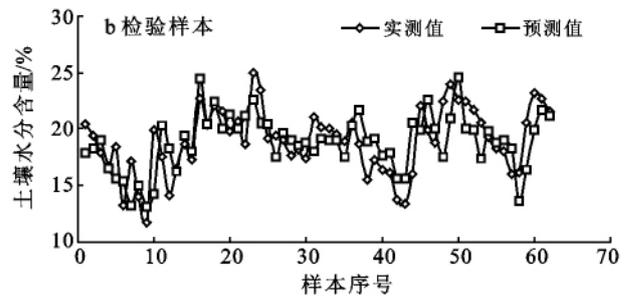
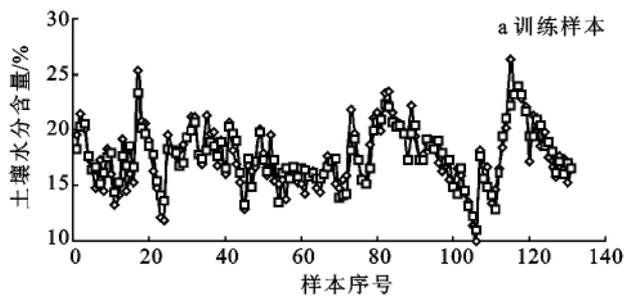


图 2 临沂站 20 cm 旬土壤水分含量预测结果

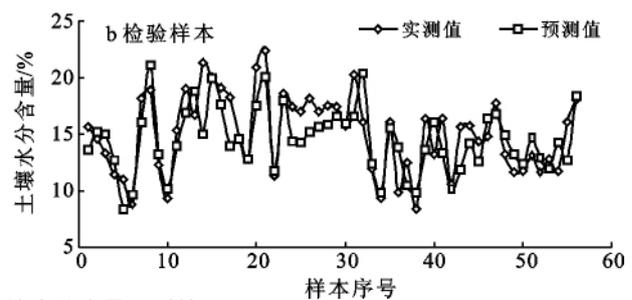
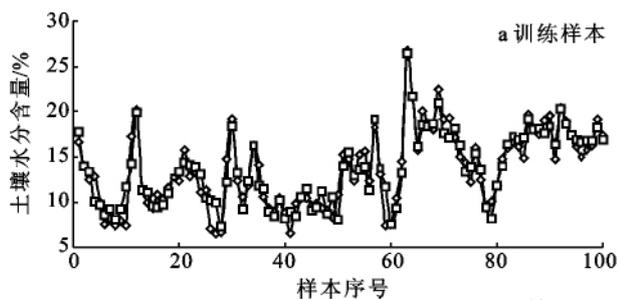


图 3 平邑站 20 cm 旬土壤水分含量预测结果

3 结论

(1) 土壤水分预测过程及绝对误差和相对误差的统计结果表明,ENN 能对土壤墒情进行成功模拟,预测的土壤水分值与观测值在整个过程都吻合得较好,临沂站和平邑站的平均绝对误差分别为 1.08% 和 1.07%,平均相对误差为 10.2% 和 11.0%,模拟精度较高。

(2) ENN 能够从时空变率复杂的土壤水分运移系统中找出一定的演变规律,为土壤水分预测提供了一种有效可靠的方法。本研究由于收集的资料有限,假定灌水、径流量、渗漏量为常量,同时未考虑地下水的影响,难免带来一些误差,为了更好地验证该方法的优越性,还需要更多的样本数据、更多的区域和更全面的敏感影响因素来验证,以及更深层次的理论研究和分析。

[参 考 文 献]

[1] Wang H, Flerchinger G N, Lemke R, et al. Improving SHAW long-term soil moisture prediction for continuous wheat rotations, Alberta, Canada[J]. Canadian Journal of Soil Science, 2010,90(1):37-53.
 [2] 尚松浩,雷志栋,杨诗秀. 冬小麦田间墒情预报的经验模型[J]. 农业工程学报,2000,16(5):31-33.
 [3] 李明生,刘震. 土层水量平衡模型在土壤墒情预报中的应用[J]. 东北水利水电,2005(1):49-56.

[4] 周良臣. 利用土壤水动力学模型预测麦田土壤水分的研究[J]. 节水灌溉,2007(3):10-17.
 [5] 高如泰,陈焕伟,李保国,等. 基于 BP 神经网络的土壤水力学参数预测[J]. 土壤通报,2005,36(5):641-646.
 [6] 刘洪斌,王伟,魏朝富,等. 土壤水分预测神经网络模型和时间序列模型比较研究[J]. 农业工程学报,2003,19(4):33-36.
 [7] Yang S H, Wang Y M. An artificial neural network model for soil moisture prediction responding to weather parameters[C]//34th International Symposium on Agricultural Engineering: Opatija, Croatia, 2006:213-218.
 [8] 刘洪斌,王伟,魏朝富. 基于神经网络的土壤水分预测建模研究[J]. 水土保持学报,2003,17(5):59-62.
 [9] Tang W M. The study of the optimal structure of BP neural network[J]. Systems Engineering Theory and Practice, 2005, 25(10): 95-100.
 [10] Tommy W S, Chow Y F. A recurrent neural network based real time learning control strategy applying to nonlinear system with unknown dynamics [J]. IEEE Transactions on Industrial Electronics, 1998, 45(1): 151-161.
 [11] Elman J L. Finding structure in time [J]. Cognitive Science, 1990, 14(2): 179-211.
 [12] Shi X H, Liang Y C, Lee H P. Improved Elman networks and applications for controlling ultrasonic motors [J]. Applied Artificial Intelligence, 2004, 18(7): 603-629.