

农田土壤湿度的人工神经网络 预报模型研究

金 龙

(江苏省气象科学研究所, 南京 210008)

罗 莹

(江苏省气候应用所)

缪启龙 申双和

(南京气象学院)

摘 要

基于多层误差反传网络结构模型和一维时间序列拓展的方法,发展了一种新的旱季农田土壤湿度预报模式。该模式不仅预报准确性高,而且不受中期降水预报准确性的影响。一般只要具备386以上的计算机条件即可进行工作,十分便于业务预报推广。可为我国干旱地区或季节的农业区土壤水资源的合理利用和防旱抗旱,减少光、热农业气候资源的浪费提供有效的新方法。同时也为充分利用宝贵的土壤湿度观测资料开辟了途径。

关键词 旱季,土壤湿度,神经网络,预报模式

目前,随着工农业生产的发展和人口的增长,占总耗水量80%以上的农业用水日趋紧张,而我国的农业生产属于气候型农业,作物产量受气象条件变化影响极大,特别是旱涝灾害对农业生产的危害。一般在我国干旱地区或季节的农业区,一个重要的突出矛盾是光热资源特别充分,而相应的水资源却往往严重匮乏。这严重地阻碍了宝贵的农业气候资源利用。由实际农业生产情况知道,作物生长的水资源条件最终是反映在土壤水分条件的好坏。因此,在我国大范围易受干旱的地区和季节,一种直接有效的方法是充分挖掘和提高现有土壤水资源的利用率,和减少光热资源的浪费,这对于提高农业生产水平是十分有效的。为此,这不仅需要充分了解土壤水分的各种时间尺度的演变特征和传输过程,而更为重要的是掌握了解未来时段土壤水分条件的好坏,特别是作物主要生长期和关键需水期的土壤水分状况。由此可见,在干旱地区和季节,研究探讨实用的土壤湿度预报新方法,提高预报水平,对于充分利用农业气候资源,提高作物产量,为农业生产合理用水和防灾减灾提供科学决策依据,具有十分重要的实际生产意义。

1 方法的原理和实现

1.1 新方法的提出

目前关于土壤湿度预报的研究和应用主要可分为两类,一类主要是以气象和农业气

象要素与土壤水相关关系为基础的统计预报方法^[1]。另一类则主要是从土壤水分平衡方程出发来估算未来的土壤水分状况^[2]。并且这两类预报方法已在国内外的实际业务预报中得到了应用^[3,4]。在各种土壤水分动态模拟和预报方法的研究中,较为困难的是确定对土壤湿度有重要影响的未来预报时刻的降水量多少,因此一些研究或者是假定为已知或者直接引用中期降水天气预报的结果^[5,6]。当前天气预报急待解决的重要课题就是提高中期降水预报的准确性。因而,当未来降水量假定为已知时,实际上是对未来土壤湿度模拟,没有真正的预报意义。而如果直接根据中期降水预报结果作土壤湿度预报,则降水预报的准确性会直接影响土壤湿度的预报精度。另外,由于土壤湿度的自身变化受大气-土壤-作物甚至地下水的多种因素综合影响,也给土壤湿度的模拟和预报工作带来了更多的困难。本文试图从另一个角度出发来探讨能适用于干旱季节的新的土壤湿度预报模式。

由实际的土壤湿度观测资料计算分析可以发现,除了降水量以外,前期土壤湿度对后期土壤湿度状况有着重要影响。能否从实测土壤湿度一维时间序列中寻找出有用的信息,这是要研究的新问题。文献[7]已通过对月平均气温,逐日气压等气象要素一维时间序列的分数维, Kolmogorov 熵等计算分析,得到了一些有意义的结果。本文则尝试把土壤湿度的一维时间序列作漂移,拓展为多维序列,并根据土壤湿度变化受多种因素影响特征。结合采用能适合处理因果关系不甚明确,推理规则不完全确定的复杂的非线性问题,并具有容错性和学习功能的人工神经网络方法来探讨一种不直接依赖于中期降水预报,而且便于日常业务预报推广的土壤湿度预报新方法。

1.2 人工神经网络

人工神经网络(ANN)是80年代以来国际上迅速兴起的非线性科学,尤其近10年来形成了第二次研究新热潮,并且在人工智能、信号处理、自动控制和模式识别等研究领域取得了令人瞩目的研究成果^[8-10]。人工神经网络是一种模仿人脑基本结构和功能来处理非线性高维与高阶性知识信息问题的有力的新方法,其特点是它具有很强的自组织,自适应学习和记忆联想能力。在各种人工神经网络的模型中,目前应用最为广泛的多层误差反传网络模型是一种多层非线性映射网络^[11],它是采用最小均方差学习方式,在进行输入样本和期望输出的网络学习时是一种有教师的训练。学习阶段是由输出层误差反向逐层传播到输入层,然后把所得结果与所需结果进行比较,如果两者相差很大,则通过调节连接权重再反传通过网络。如此反复,只有当实际输出与期望输出之间差距足够小时,才能说明网络学会了输入信息。人工神经网络的这种自适应学习能力和记忆联想能力,使得它为了解决复杂的非线性高维问题提供了有力的工具,并且展示了广阔的前景。

1.3 三层误差反传网络方法的实现

本文在研究旱季土壤湿度预报模型时,从众多的人工神经网络模型中选用误差反传(Back Propagation)网络模型主要是因为,B-P算法不仅理论依据坚实,物理概念清晰,通用性好。并且网络在学习训练时,除了学习因子和动量因子事先选定外,网络的大量参数是网络对输入的原始数据进行不断学习后获得的。即B-P网络是通过学习,从原始数据中“提取”信息逼近规律,而不是人为赋予某种规律的。

以下以三层B-P网络为例,具体证明给出网络的训练方法和过程。该网络包括一个输入层,一个输出层和一个隐含层(如果是多层网络则有多个隐含层)。设网络的学习样

本输入和期望输出为 $A_k, C_k (k = 1, 2, \dots, m)$ 。随机地给出网络从输入层到隐含层的初始连接权值为一组随机小量 V_{hi} , 同时也随机地给出一组隐含层到输出层的连接权函数 W_{ij} 以及隐含层单元的阈值 θ_i 和输出层单元的阈值 γ_j 。然后我们对学习样本输入和期望输出 $A_k, C_k (k = 1, 2, \dots, m)$ 进行下列计算:

(1) 根据连接权矩阵(初始时刻为给定的一组随机小量)和学习样本的输入计算隐含层新的激活值:

$$b_i = f \left(\sum_{h=1}^n a_h V_{hi} + \theta_i \right) \quad (1)$$

其中 $i = 1, 2, \dots, p$, 激活值函数为 Sigmoid 函数:

$$f(x) = 1 / (1 + e^{-x}) \quad (2)$$

(2) 计算输出层单元的激活值:

$$C_j = f \left(\sum_{i=1}^p W_{ij} b_i + \gamma_j \right) \quad (3)$$

其中 $j = 1, 2, \dots, q$, (初始时刻 W_{ij} 为一组给定的随机小量)

(3) 计算输出层单元的一般化误差:

$$d_j = C_j(1 - C_j)(C_j^k - C_j) \quad (4)$$

其中 $j = 1, 2, \dots, q$, C_j^k 为输出层单元 j 的期望输出

(4) 计算隐含层单元相对于每个 d_j 的误差:

$$e_i = b_i(1 - b_i) \sum_{j=1}^q W_{ij} d_j \quad (5)$$

其中 $i = 1, 2, \dots, p$ 。

(5) 调整隐含层单元到输出层单元的连接权值:

$$\Delta W_{ij} = \alpha b_i d_j \quad (6)$$

其中 $i = 1, 2, \dots, p$ 和 $j = 1, 2, \dots, q$, α 为学习因子 ($0 < \alpha < 1$)

(6) 调整输出层单元的阈值:

$$\Delta \gamma_j = \alpha d_j \quad (7)$$

其中 $j = 1, 2, \dots, q$ 。

(7) 调整输入层单元到隐含层单元的连接权值:

$$\Delta V_{hi} = \beta a_h e_i \quad (8)$$

其中 $h = 1, 2, \dots, n$ 和 $i = 1, 2, \dots, p$, β 为动量因子 ($0 < \beta < 1$)

(8) 调整隐含层单元的阈值:

$$\Delta \theta_i = \beta e_i \quad (9)$$

(9) 重复第(1)到第(8)式的计算步骤, 直到 $j = 1, 2, \dots, q$, 和 $k = 1, 2, \dots, m$, 计算实际输出与期望输出的误差, 当全部样本的输出误差小于设定的收敛误差时, 训练结束。在训练过程中, B-P网络的权值是被逐步调整的, 通过训练, 网络从实际输入样本中获得

了知识信息。并且可以看到,存贮神经网络知识的正是由隐含层连接起来的输入层和输出层的连接权值和相应的阈值。当网络学习结束后,这些连接权值和阈值都确定了,根据这些参数和实际资料输入,只要进行一些简单的加法和乘法运算即可进行预报。

2 方法的应用

江苏省淮北地区春季是全省干旱最频繁的地区,并且这是主要的作物—冬小麦的主要生长期和关键需水期,水分条件对小麦生长和产量具有重要影响^[12]。我们取该地区徐州农业气象试验站的土壤湿度观测资料进行预报研究。该观测点为冬小麦田,土壤性质为轻壤土,肥力中等,土壤湿度观测方法为土钻法。我们取该站两个相邻的中等干旱年型—1983年和1984年作为基准,将1983年36个旬以及紧连的1984年第1—6旬,连续42个旬0—50cm 6个土层深度的土壤湿度观测资料作为神经网络学习的基本原始数据,并且将1984年春季(第7—15旬)0—50cm的土壤湿度资料作为独立样本预报检验资料。

首先计算出各个旬0—50cm土壤层的相对土壤湿度平均值(\bar{x}),为了进一步满足B-P网络Sigmoid函数的条件,对一维土壤湿度观测序列(\bar{x})作如下变换:

$$E_i = \frac{\bar{x}_i - (s_{\min} - \delta)}{(s_{\max} - \delta) - s_{\min}} \quad (10)$$

式中 s_{\min} 和 s_{\max} 为样本序列中最小值和最大值, δ 取一小量,以保证变换后的 E_i 序列最大值略小于1和最小值略大于0。再根据文献[7],按后延时间 τ 将变换后的土壤湿度一维时间序列(E_i)作飘移,拓展成多维序列。其具体计算公式为,对于一维时间序列:

$$E(t_1), E(t_2), \dots, E(t_n) \quad (11)$$

按以下公式将其拓展成多维序列:

$$\begin{cases} E(t_1), & E(t_2), & \dots, E(t_m) \\ E(t_1 + \tau), & E(t_2 + \tau), & \dots, E(t_m + \tau) \\ \vdots & \vdots & \vdots \\ E(t_1 + k\tau), & E(t_2 + k\tau), & \dots, E(t_m + k\tau) \end{cases} \quad (12)$$

其中 $m < n$ 。

取 $E(t_m), E(t_m + \tau), \dots, E(t_m + k\tau)$ 序列作为学习网络的期望输出,其余序列作为网络学习的输入样本。本文在实际计算时是将1维观测序列,延拓为9维,因此,网络的实际学习样本长度为34。表1给出了由(10)和(12)式变换得出的徐州农试站1983年1月上旬至1984年2月下旬,0—50cm土壤层平均土壤湿度人工神经网络学习样本输入矩阵和期望输出。

采用的三层误差反传(B-P)网络输入层为8个节点,隐含层包括8个隐节点,输出节点为1。取定网络学习的收敛误差为0.0007,学习因子和动量因子分别取为0.9和0.7。根据公式(1)到(9),经过1974次运算,收敛误差达到标准,学习结束。网络学习的拟合值和实测值变化见图1。由图1可以看出,网络经过学习后拟合效果是令人满意的。然后,根据

表1 标准化B-P网络训练集

Table 1 Standardization training set of the network (B-P)

学 习 样 本 输 入								期望输出
Learning samples to input								Hope to output
0.639	0.665	0.642	0.581	0.600	0.563	0.783	0.595	0.634
0.665	0.642	0.581	0.600	0.563	0.783	0.595	0.634	0.405
0.642	0.581	0.600	0.563	0.783	0.595	0.634	0.405	0.382
0.581	0.600	0.563	0.783	0.595	0.634	0.405	0.382	0.277
0.600	0.563	0.783	0.595	0.634	0.405	0.382	0.277	0.230
0.563	0.783	0.595	0.634	0.405	0.382	0.277	0.230	0.088
0.783	0.595	0.634	0.405	0.382	0.277	0.230	0.088	0.304
0.595	0.634	0.405	0.382	0.277	0.230	0.088	0.304	0.233
0.634	0.405	0.382	0.277	0.230	0.088	0.304	0.233	0.346
0.405	0.382	0.277	0.230	0.088	0.304	0.233	0.346	0.322
0.382	0.277	0.230	0.088	0.304	0.233	0.346	0.322	0.329
0.277	0.230	0.088	0.304	0.233	0.346	0.322	0.329	0.748
0.230	0.088	0.304	0.233	0.346	0.322	0.329	0.748	0.729
0.088	0.304	0.233	0.346	0.322	0.329	0.748	0.729	0.520
0.304	0.233	0.346	0.322	0.329	0.748	0.729	0.520	0.258
0.233	0.346	0.322	0.329	0.748	0.729	0.520	0.258	0.548
0.346	0.322	0.329	0.748	0.729	0.520	0.258	0.548	0.468
0.322	0.329	0.748	0.729	0.520	0.258	0.548	0.468	0.508
0.329	0.748	0.729	0.520	0.258	0.548	0.468	0.508	0.568
0.748	0.729	0.520	0.258	0.548	0.468	0.508	0.568	0.697
0.729	0.520	0.258	0.548	0.468	0.508	0.568	0.697	0.848
0.520	0.258	0.548	0.468	0.508	0.568	0.697	0.848	0.749
0.258	0.548	0.468	0.508	0.568	0.697	0.848	0.749	0.628
0.548	0.468	0.508	0.568	0.697	0.848	0.749	0.628	0.548
0.468	0.508	0.568	0.697	0.848	0.749	0.628	0.548	0.597
0.508	0.568	0.697	0.848	0.749	0.628	0.548	0.597	0.553
0.568	0.697	0.848	0.749	0.628	0.548	0.597	0.553	0.573
0.697	0.848	0.749	0.628	0.548	0.597	0.553	0.573	0.646
0.848	0.749	0.628	0.548	0.597	0.553	0.573	0.646	0.612
0.749	0.628	0.548	0.597	0.553	0.573	0.646	0.612	0.634
0.628	0.548	0.597	0.553	0.573	0.646	0.612	0.634	0.654
0.548	0.597	0.553	0.573	0.646	0.612	0.634	0.654	0.552
0.597	0.553	0.573	0.646	0.612	0.634	0.654	0.552	0.652
0.553	0.573	0.646	0.612	0.634	0.654	0.552	0.652	0.568

训练好的网络参数,对未参加学习的1984年春季第一个月(3月)3个旬的土壤湿度样本进行预报,并对这3个旬的独立样本预报结果进行检验,确定其预报精度,预报结束。然后,将3月份这3个旬的土壤湿度作为已知样本,加入B-P网络的学习输入样本,仍应用三层




图1 三层B-P网络期望输出(虚线)、实际输出(实线)

Fig.1 The expectance export (broken lines) and real export (solid lines) of the network (B-P)

个旬的土壤湿度资料加入学习输入样本,采用与前面相同的模型、参数,对网络再次作学习训练。同样当收敛度达到 0.0007 时(计算次数为 1942),网络学习结束,并对未参加学习的 1984 年 5 月份 3 个旬进行逐旬的预报,作预报精度检验。表 2 给出了春季(3—5 月)9 个旬 0—50cm 土层内平均土壤湿度预报结果和预报结果的检验。由表 2 可见,预报精度是令人满意的,9 个旬的预报平均相对误差为 7%,其中最大相对误差为 -15.9%,最小相对误差为 0.4%。

表2 春季各旬土壤湿度预报结果检验

Table 2 The test for the forecast results of the soil moisture in spring

月 日	实测值%	预报值%	绝对误差%	相对误差%
Month day	Observation value	Prediction value	Absolute error	Relative error
3.8	20.97	22.34	-1.37	-6.9
3.18	21.23	20.43	0.8	3.7
3.28	19.33	21.30	-1.97	-10.2
4.8	20.23	19.09	1.21	5.9
4.18	16.80	19.48	-2.68	-15.9
4.28	17.90	17.82	0.08	0.4
5.8	14.07	14.69	-0.62	-4.4
5.18	14.72	14.12	0.6	4.1
5.28	15.62	13.71	1.91	12.1
平均			1.25	7.06

由以上进行的预报步骤,我们可以清楚地看到,对于春季 9 个旬的土壤湿度预报具有真正意义上的试验预报。因为在对每次人工神经网络学习时,未来预报旬的样本不参加网络学习,并且网络第一次训练时选择确定的模型结构及学习因子和动量因子保持不变,更重要的是收敛误差也一直保持不变,其各种步骤与实际预报是类同的。另外,我们还可以看到在本文所进行的试验预报过程中,避免了中期降水预报准确性对土壤湿度预报的可能影响。此外,以往的土壤湿度统计预报方法大多是建立在历史上预报因子与土壤湿度预报量之间具有较好的相关关系基础上的,其拟合效果一般都较好。而在作未来时刻的预报时与拟合效果常常不一致,这主要是因为前期选定的相关关系,并不能一定保证这

B-P网络对学习样本进行学习训练,并且各输入、输出和隐含层的节点数等保持不变,网络重新作训练,同样当收敛度达到 0.0007(这时计算次数为 1985 次),学习结束。再利用网络学习获得的新参数,对未参加学习的 1984 年春季第二个月(4 月)3 个旬的土壤湿度进行逐旬的预报并作预报结果检验。然后再将 4 月份 3

种好的相关在后期也是这样维持。而本文采用将一维时间序列作拓展和人工神经网络相结合的方法,进行土壤湿度试验预报研究,则避免了未来的相关必须与前期已知相关类同的假设条件,而这种假设条件的成立在不少情况下,当实况出现以前是难以保证的。因此,从这个意义上讲,本文尝试研究的这种预报新方法比传统的相关统计预报方法更具有实际预报意义。同时,本文的独立样本预报检验与实际预报结果验证情况更为类同也是显见的。

3 结 语

本文的试验研究结果表明,将土壤湿度一维时间序列作飘移,拓展成多维序列再结合三层 B-P 网络模型所建立的旱季农田土壤湿度预报模式,其预报精度能满足日常业务预报的要求。同时,由于网络模型在学习训练后,只要进行简单的运算即可作出未来时刻的土壤湿度预报,十分适合于业务预报推广。然而采用人工神经网络和一维时间序列拓展的方法,从土壤湿度实测序列中发掘有用的信息是一种新的尝试。其结果确实包含有以前很少利用的有用信息。因此,对于不同的气候条件下各种土壤类型和土壤深度的土壤湿度人工神经网络预报模式,还有待于进一步的深入研究。此外,研究中还发现,多层 B-P 网络方法虽然是一种处理非线性复杂问题的有力工具,但有时 B-P 算法的学习训练过程中收敛速度较慢。当学习样本较大,研究问题属于高维高阶问题而隐含层、输入和输出层节点较多时,一般要用 486 以上的计算机才能满足计算速度的要求。在网络训练时,有时还会在极小点附近产生振荡导致不收敛以及根据不同的输入样本矩阵,怎样选取更合适的模型结构、学习参数和节点数等有关问题,均有待于进一步深入探讨。

参 考 文 献

1. 王馥棠,冯定原,张宏铭等. 农业气象预报概论. 北京:农业出版社,1991. 383—397
2. 卢玉邦. 土壤水分预报模型的研究. 土壤学报,1989,26(1): 51—56
3. Baier W., Robertson, Geo.W. A new versatile soil moisture budget. Canadian Journal of Plant Science, 1966,46:299—315
4. 裴步祥,毛飞,吕厚荃. 我国北方春季土壤水分动态模拟预报模式的试验研究. 北京农业大学学报,1990,16: 116—122(增刊)
5. 陈艳春,欧阳海. 陕西、陇东农田土壤水分动态模拟预测研究. 南京气象学院学报,1992,15(1):117—123
6. Bhaskar Choudhury Simulationg the effects of weather variables and soil water potential on a corn canopy temperature. Agri Meteo, 1983,29(3):169—183
7. Yan, S.J., Peng, Y.Q., Wang, J.Z. Determintion of kolmog-oroov entropy of chaotic attractor included in 1-D time series of meteorological data. AAS, 1991, 8(2):243—251
8. Widrow, B., Lehr, M.A. 30 years of adaptive networks: precetron, madaline, and backpropagation. Proc. of the IEEE,1990,78(9):1414—1441
9. Lippmann, R.P. An introduction to computing with neural network. IEEE ASSP Magazine, 1987, 4—22
10. Fernado, M.S.,Lurs, B.A. Acceleration techniques for backpropagation algorithm. Neural Networks, 1990,1(4): 351—370
11. Hechi-Nielsen, R. Theory of the back propagation neural network. Int. J. Corff. on Neural Network,

Washington D. C., 1989, 1:593—605

12. 金龙, 罗莹. 淮北平原水分盈亏量的综合研究. 气象科学, 1992, 12(1): 24—31

FORECAST MODEL OF FARMLAND SOIL MOISTURE BY ARTIFICIAL NEURAL NETWORK

Jin Long

(Meteorological Research Institute, Jiangsu Province, Nanjing 210008)

Luo Ying

(Institute of Climate Application, Jiangsu Province)

Miao Qi-long Shen Shuang-he

(Nanjing Institute of Meteorology)

Summary

A new forecast method of the field soil moisture in dry season is built based on the artificial neural networks of the backpropagation model. The results showed that the forecast accuracy is high enough as compared with the measured values. In general, this method is suitable for routine forecast of the soil moisture in computer condition of IBM PC / 386. This new method can be used to study the rational utilization of the soil moisture resources and to decrease the waste of agrometeorologic resources of the light and heat for the dry farming regions and dry season in China. It is likely to be a new approach to use valuable observational data of soil moisture.

Key words Dry season, Soil moisture, Neural network, Forecast model