基于气象因子的长三角地区农田站点土壤水分时间序列预测

李柳阳[1,2]，朱 青[1,2]，刘 亚[1,2]，廖凯华[1,2]，赖晓明[1,2]

(1.中国科学院南京地理与湖泊研究所，中国科学院流域地理学重点实验室，南京 210008；2.中国科学院大学，北京 100049)

摘要： 以长三角 3 省 1 市为研究区，旨在构建长三角地区土壤水分长时间序列，为农业生产和遥感算法提供数据支撑。研究基于空间匹配的站点土壤水分数据和气象数据，利用主成分分析得到 4 个有效主成分作为线性回归和 BP 神经网络模型的输入因子，建立土壤水分与气象因子间的定量关系，并评估所构建模型的精度。结果表明，基于全部站点数据建立的单一 BP 神经网络模型优于单一线性回归模型。单一线性回归模型的 $R^2=0.34$，RMSE=0.046 m^3/m^3，MAE=3.67%；而单一 BP 神经网络模型的训练、验证和测试 3 个数据集的 R^2 均在 0.64 以上，RMSE<0.043 m^3/m^3，MAE 低于 3.4%。根据逐个站点分别构建分站点的 BP 神经网络模型，其总体精度高于基于全部站点数据构建的单一 BP 神经网络模型。分站点构建的 BP 神经网络模型的总体精度方面，3 个数据集的 R^2 均值在 0.75 以上，RMSE<0.039 m^3/m^3，MAE 低于 3%。通过对逐个站点分别构建 BP 神经网络模型，获得了精度较高、较稳定的土壤水分拟合结果。

关键词： 土壤水文；时空变化；长三角；遥感反演

中图分类号： S152.7　　**文献标识码：** A　　**文章编号：** 1009-2242(2021)02-0131-07

DOI： 10.13870/j.cnki.stbcxb.2021.02.018

Time Series Prediction of In-situ Soil Moisture Based on Meteorological Data in the Yangtze River Delta

LI Liuyang[1,2], ZHU Qing[1,2], LIU Ya[1,2], LIAO Kaihua[1,2], LAI Xiaoming[1,2]

(1.*Key Laboratory of Watershed Geographic Sciences*, *Nanjing Institute of Geography and Limnology*, *CAS*, *Nanjing* 210008; 2.*University of Chinese Academy of Sciences*, *Beijing* 100049)

Abstract: In order to construct a long-term series of soil moisture in the Yangtze River Delta, which is frequently used for the validation of various satellite products and agricultural production, the linear regression and BP neural network models were constructed respectively to describe the quantitative relationship between soil moisture and meteorological factors. Based on the paired data of in-situ soil moisture and meteorological observation in the Yangtze River Delta including the city of Shanghai and the provinces of Jiangsu, Anhui and Zhejiang, four effective principal components were obtained by principal component analysis as the input of the established models, and the accuracies of these models were evaluated systematically. The results showed that, although both based on all paired data from soil moisture and meteorological observation, the prediction accuracy of the single BP neural network model (the R^2 were all above 0.64, and RMSE and MAE were less than 0.043 m^3/m^3 and 3.4% separately in the sets of the training, validation and testing data) was better than the single linear regression model (R^2, RMSE and MAE were 0.34, 0.046 m^3/m^3 and 3.67% respectively). However, accuracies of both these models were worse than the BP neural network models based on each paired soil moisture and meteorological observation data, with the average of R^2 above 0.75, and RMSE and MAE less than 0.039 m^3/m^3 and 3% respectively. By constructing the BP neural network models based on each paired soil moisture and meteorological observation data, a more accurate and stable soil moisture fitting result was obtained.

Keywords: soil hydrology; temporal and spatial changes; the Yangtze River Delta; remote sensing inversion

收稿日期： 2020-08-28

资助项目： 国家自然科学基金项目(41971117)；中国科学院前沿科学重点研究项目(QYZDB-SSW-DQC038)

第一作者： 李柳阳(1992—)，女，博士研究生，主要从事土壤水遥感反演研究。E-mail：18317857228@163.com

通信作者： 朱青(1980—)，男，研究员，主要从事流域水文土壤过程及营养盐输移探测模拟研究。E-mail：qzhu@niglas.ac.cn

土壤水分作为地球表层不同圈层相互作用的关键参数，是地表物质循环与能量转换的重要载体和驱动力[1-2]。土壤水分影响地表植被的蒸腾作用和光合作用，影响土壤中微生物的生长和活动，并参与土壤中有机碳循环，是陆地生态系统的重要控制因子[3-4]。同时，土壤水分通过改变地表反射率、热容量和蒸散发强度，以及调节显热、潜热通量，对气候变化起着反馈调节的作用[5-6]。此外，土壤水分还与流域农业生产、气象与地质灾害、水环境、水文循环等密切相关[7]，从而作用于国民经济和人类生活。因此，精确获取土壤水分信息具有重要的现实意义。

土壤水分数据常用的获取方式主要包括地面传统监测和遥感反演 2 种。传统地面实测方法主要采用负压计、电子仪和时域反射仪等仪器来测定土壤中水分含量或能态。其观测精度高，受环境影响较小，但费用高且费时费力，采样时空分辨率难以兼顾[8-9]。这些特点导致地面实测的土壤水分数据不能满足大范围、长时序的研究需求。卫星遥感凭借其高时效、长序列、强动态和大面积监测等优点，成为“面域”土壤水分数据获取的常用方式[10-12]。但其监测深度仅限于地表厘米范围内，大多用于植被稀少地区。同时，遥感反演土壤水分模型的建立依赖于有效、准确、丰富的地面实测数据[8,13]。然而我国现有的土壤水分实测数据时序较短，以农业旬报为主，缺测时有发生，使得实际获得的土壤水分数据非常有限[13]。因此地面实测数据的补充和时序的延长成为当前研究工作的重点。

土壤水分时序数据的预测方法主要分为模型预测和数据驱动预测 2 类。模型预测方法可分为基于物理机制的模型和基于土壤水分平衡方程的模型，如 Hydrus、SWAT（soil and water assessment tool）、VIC（variable infiltration capacity）等[14-16]。但此方法输入参数种类多，模型结构复杂，对计算效率要求较高，预测结果的差异性较大，导致普适性较差[9,17]。以气象或作物要素与土壤水分关系为基础的数据驱动方法，其形式和操作简单，参数易于获取，逐渐应用于土壤水分的测定和预报研究中[18-20]。其中，大多数学者主要考虑土壤水分和与之对应的即时气象因子的关系，如杨娜等[13]以甘肃省为研究区域建立了多个气象要素为输入、土壤水分为输出的 BP 神经网络模型。而少部分学者加入了气象因子对土壤水分影响的滞后性，如薛晓萍等[8]基于前期气象因子，利用支持向量机（SVM）方法建立土壤水分预测模型，具有较高的预测精度。此外，当前关于区域尺度站点土壤水分的预测研究中常采用单一的模型，而忽略了土壤水分与气象因子之间的空间差异性。例如，冯徽徽等[21]采用回归分析和线性拉伸的方法校准高植被覆盖区 AMSR-E 的低精度土壤水分数据，线性拉伸方法强调所有像元具有相同的均值和方差，而忽略了土壤水分的空间差异性；王青青等[22]利用 BP 神经网络模型预测安徽省土壤水分发现，单一模型不能较好地表达土壤水分的时间和空间差异。

针对现有研究较少考虑气象因子滞后性对土壤水分的影响，以及采用单一模型不能很好体现土壤水分与气象因子的定量关系在空间上的差异性等问题，本文拟对比线性模型和神经网络模型，构建长三角地区农田站点土壤水分和气象因子间的定量关系，对比基于全部站点建立的单一模型和针对每个站点构建的分站点模型的精度差异，寻求最优的站点土壤水分数据时间序列的预测和补充方法。

1 数据与方法

1.1 研究区概况

以长三角（江苏省、安徽省、浙江省和上海市）为研究区域（图 1），其经纬度范围是 27°12′—35°20′N，114°54′—122°42′E，面积约为 3.61×10^5 km^2。长三角地区以季风气候为主，淮河以南为亚热带季风气候，淮河以北为温带季风气候。该地区土地利用类型多样，以耕地和林地为主（土地利用类型数据来自清华大学 2015 年 30 m 分辨率的地表覆盖图，http://data.ess.tsinghua.edu.cn/）。地势总体西南高、东北低。根据地形地貌特点大致可分为 3 部分：北部为黄淮平原，中部为长江中下游平原，南部为低山丘陵地区；区域内水资源分布不均衡，土壤水分含量差异较大[20,23]。

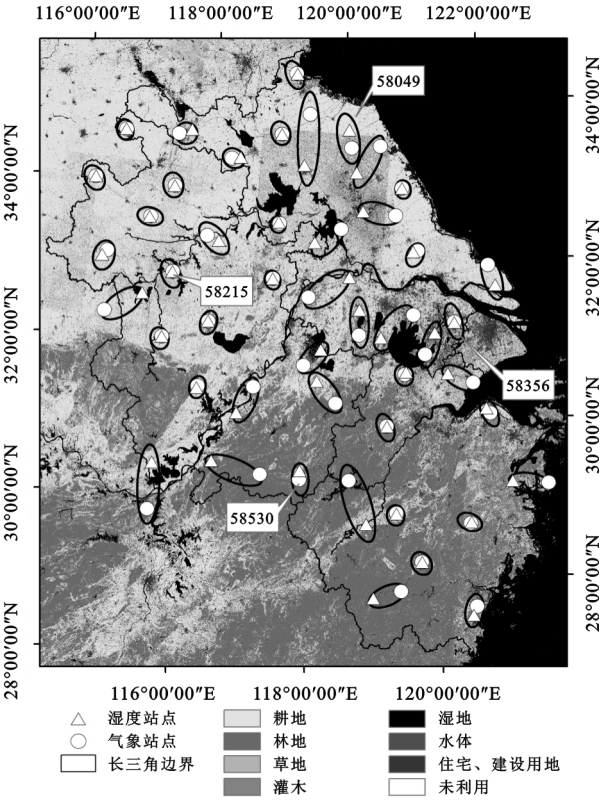

图 1 研究区农田土壤湿度站点和气象站点示意

1.2　数据来源与处理

从国家气象科学数据中心（http://data.cma.cn/）的“中国农作物生长发育和农田土壤湿度旬值数据集”获取 1993—2013 的 10 cm 深度的土壤相对湿度站点实测数据。气象要素数据来自“中国地面气候资料日值数据集（V3.0）”的逐日气象观测，包括气压、气温、降水量、蒸发量、相对湿度、风向风速、日照时间和 0 cm 地温，其时间范围为 1951 年至今。研究区内有效的土壤相对湿度站点共 47 个。以土壤相对湿度站点为基准，气象站点以距离最近的原则与湿度站点进行匹配，站点匹配结果见图 1。

1.2.1　*土壤相对湿度数据转化*　不同站点土壤相对湿度观测数据存在一定的误差，因此需要前期的质量控制。考虑到土壤相对湿度数据来源于农田，人为灌溉对其影响较大，结合降雨资料，剔除无降雨事件发生时土壤相对湿度突然明显增大的数据[24]。利用 Zhang 等[25]提供的土壤容重数据和田间持水量数据将获取的土壤相对湿度（%）转化为土壤体积含水量（即下文中的水分），转换公式为：

$$S_v = S_r \delta \theta_f \tag{1}$$

式中：S_v 为土壤体积含水量（m^3/m^3）；S_r 为土壤相对湿度（%）；δ 为土壤容重（g/m^3）；θ_f 为田间持水量（m^3/m^3）。

1.2.2　*气象数据处理*　气象要素数据的处理主要包括数据的合并、提取、缺省值的设置和单位转换。土壤相对湿度数据以旬为时间分辨率，观测时间为每月的 8，18，28 日，因此将逐日气象数据按相同日期作旬平均。由于气象要素对土壤水分的影响有一定滞后性，某日土壤水分可能与前期气象要素也具有较好的相关性[26]。本文的气温要素中加入某日（8，18，28 日）前 3 天和后 3 天的 7 天平均气温，降水要素中增加某日（8，18，28 日）前 6 天和当日的 7 天累积降水量。共选择平均气温（T_mean）、某日 7 天平均气温（T_7days）、相对湿度（RH_mean）、平均风速（WS_mean）、日照时间（DH_mean）、降水量（PRCP）、某日 7 天累积降水量（PRCP_7days）和 0 cm 平均地温（ST_mean）8 个气象要素。

1.3　线性与非线性模型构建

1.3.1　*基本统计分析*　本文匹配的 47 组土壤相对湿度站点和逐日气象站点，时间跨度为 1993—2013 年共 21 年。为衡量各气象因子与土壤水分的相关程度，将 8 个气象因子和实测土壤水分数据进行 Pearson 相关分析。在相关性分析的基础上，将 8 个气象因子进行主成分回归分析。具体步骤包括：(1)通过 KMO（Kaiser－Meyer－Olkin）和 Bartlett 的球形度检验，判断气象因子是否适合做主成分分析；(2)若适宜，则对 8 个气象因子做降维处理，以特征值为 0.8 提取主成分，得到主成分表达式；(3)将主成分得分作为自变量，标准化处理的土壤体积含水量为因变量，采用最小二乘法（least square，LS）进行多元线性回归分析，构建土壤水分与气象要素主成分之间的定量关系。LS 的基本原理来自于统计学中的极大似然估计，通过最小化误差的平方和寻找数据的最佳匹配函数[27]。

1.3.2　*神经网络模型的构建*　人工神经网络（artificial neural network，ANN）是由大量简单的处理单元（或称神经元）广泛地相互连接而形成的复杂网络系统，具有大规模并行处理和分布式信息存储能力[18]。1986 年由 Rumelhart 等[20]提出的误差反向传播的多层前馈 BP（back error propagation）神经网络是目前应用最广泛的模型之一。BP 神经网络模型的核心是采用迭代梯度算法通过调整网络输出与目标之间的误差来修正其权值，使网络总误差最小。BP 神经网络模型包括网络构建、训练和预测 3 部分。在本研究中，具体为：(1)主成分得分数据为模型的输入层，将其随机分成 3 个子集，即训练数据集、验证数据集和测试数据集，比例分别为 70%，15% 和 15%。预测的土壤体积含水量为模型的输出层，其中，隐含层的神经元个数根据经验公式进行设置和调整。(2)通过输入的已知样本集进行信息的正向传递和输出层的误差反向传播，不断调整各层神经元的权值和阈值，沿着误差函数的最速下降方向收敛，直到误差小于设定值，然后将各层间连接权值和阈值信息保存起来，建立预测模型。(3)用所建立的预测模型对试验样本集进行预测结果的输出。

1.3.3　*精度评价*　选取决定系数 R^2（coefficient of determination）、均方根误差 RMSE（root mean square error）和平均绝对误差 MAE（mean absolute error）来评价预测精度。

2　结果与分析

2.1　相关性与主成分分析结果

本文 8 个气象因子与研究区站点 10 cm 深度土壤水分之间的相关性分析结果见图 2。由图 2 可知，温度、日照时间与土壤水分呈负相关；其中，日照时间与土壤水分间负相关性最大，达到－0.401；0 cm 地温与土壤水分负相关性较高，为－0.307；7 天平均气温和当天平均气温与土壤水分的负相关性相当。而相对湿度、平均风速和降水量与土壤水分呈正相关，其中相对湿度与土壤水分间的正相关性最大（相关系数为 0.368），平均风速与土壤水分间的正相关性最小（0.072）；当日降水量与土壤水分间的相关性（相关系数为 0.226）低于 7 天累计降水量和土壤水分的相关

性(相关系数为 0.260),说明土壤水分是前期降水量综合影响的结果。总体来看,气象因子对土壤水分的影响是综合的、复杂的,土壤水分和选取的 8 个特征气象要素均显著相关,可进一步用于模型的构建。

将 8 个气象因子进行主成分分析,KMO 检验值为 0.726,大于 0.5,表明变量间相关性较强,并且球状度 Bartlett 检验达到显著水平(Bartlett=481.934,$P<0.001$),说明所选气象因子适宜进行主成分分析。依据初始特征值>0.8,共提取 4 个主成分,累计贡献率为 94.68%(>85%),提取效果较好,主成分分析的部分结果见表 1。可知第 1 主成分以温度为主,第 2 主成分以日照时间和降水为主,第 3 主成分以风速为主,第 4 主成分以相对湿度为主。

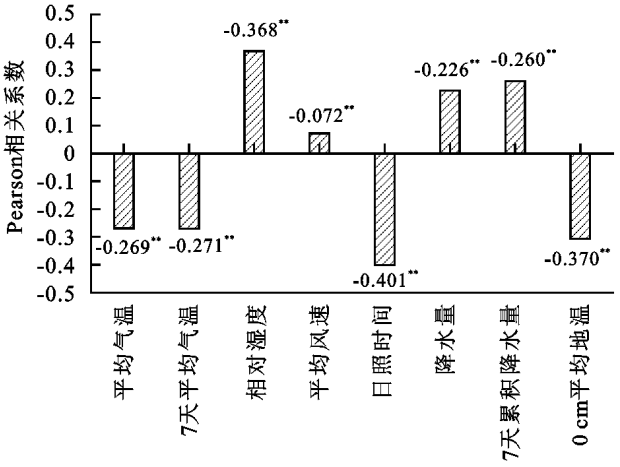

注:** 表示在 0.01 水平(双侧)上显著相关。

图 2 实测土壤水分和气象因子的 Pearson 相关系数

表 1 主成分分析结果(部分)

主成分	初始特征值			成分矩阵
	总值	方差比/%	方差累计/%	|*|>0.56(按数值递减顺序)
1	4.881	44.086	44.086	T_mean, T_7days, ST_mean
2	2.515	27.676	71.762	DH_mean, PRCP_7days, PRCP
3	1.053	12.674	84.436	WS_mean
4	0.836	10.245	94.681	RH_mean

2.2 基于全部站点构建的单一模型对比

基于全部站点构建研究区标准化处理的土壤水分和 4 个主成分间单一的线性模型和 BP 神经网络模型见图 3。单一线性模型的土壤水分预测值范围为 0.14~0.39 m^3/m^3,平均值为 0.26 m^3/m^3;单一 BP 神经网络模型的土壤水分预测值为 0.06~0.37 m^3/m^3,平均值为 0.25 m^3/m^3。总体上,基于单一线性模型的预测结果变化幅度略小于 BP 神经网络模型。单一线性模型中建模部分的 $R^2=0.35$,RMSE=0.045 m^3/m^3,MAE=3.60%,验证部分的 $R^2=0.34$,RMSE=0.046 m^3/m^3,MAE=3.67%,总体拟合效果不够理想。单一 BP 神经网络模型的 RMSE 均小于线性模型,其训练、验证、和测试数据集的 RMSE 值的范围为 0.042~0.043 m^3/m^3;MAE 值均在 3.40%以内,小于单一线性模型的预测误差;单一 BP 神经网络模型的 3 个数据集的 R^2(0.64~0.66)均高于单一线性模型的 R^2。因此,基于全部站点构建的单一 BP 神经网络模型精度优于单一线性模型。其主要原因可能是土壤水分受外界环境等因素影响较大,很难用简单的线性模型来拟合土壤水分与气象要素间的关系[26]。

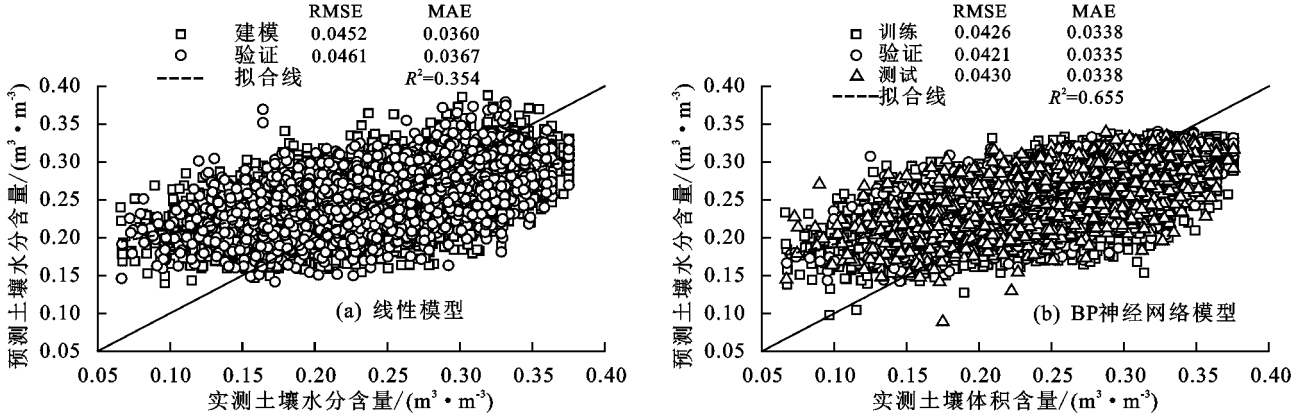

图 3 基于全站点构建的单一模型拟合结果

2.3 全站点与分站点构建的 BP 神经网络模型对比

基于每个站点分别构建的分站点 BP 神经网络模型的精度优于基于全部站点建立的单一 BP 神经网络模型(表 2 和图 4),其中分站点的精度评价指标均为 47 个站点的平均值。分站点 BP 神经网络模型的预测误差均较小,训练、验证和测试数据集的 MAE 均值为 2.21%~2.95%,相应的 RMSE 的均值为 0.029~0.039 m^3/m^3,R^2 均值为 0.75~0.86,精度参数均显著优于基于全部站点的单一 BP 预测模型。土壤水分是一个复杂的非线性耦合系统,在不同的空

间位置，土壤水分时间变化与气象因子的关系并不相同，因此，很难用一个单一的函数关系进行大范围、长时序的预测[18,20]。相关的结论在前人的研究中也有报道，刘学勤等[28]构建土壤含水率与 9 个气象因子的回归方程发现，不同坡向的回归方程中纳入的气象因子不同；孙倩倩等[29]建立了东北土壤湿度的分区回归预报模型，而各区域土壤湿度的显著影响因子有所差异；陈昌华等[30]对比了采用分区域、分阶段建立的 BP 神经网络模型与全要素 BP 神经网络模型的预测效果，在气象要素相同的条件下，分区域、分阶段的神经网络模型预测效果优于全要素 BP 神经网络模型。

表 2　全站点的单一 BP 和分站点 BP 神经网络精度对比

模型构建方法	数据集	数量	RMSE/($m^3 \cdot m^{-3}$)	MAE	R^2
全部站点单一 BP	训练集	9957	0.043	0.034	0.659
	验证集	2133	0.042	0.034	0.649
	测试集	2133	0.043	0.034	0.641
分站点 BP	训练集	9953	0.029	0.022	0.856
	验证集	2135	0.035	0.027	0.793
	测试集	2135	0.039	0.030	0.749

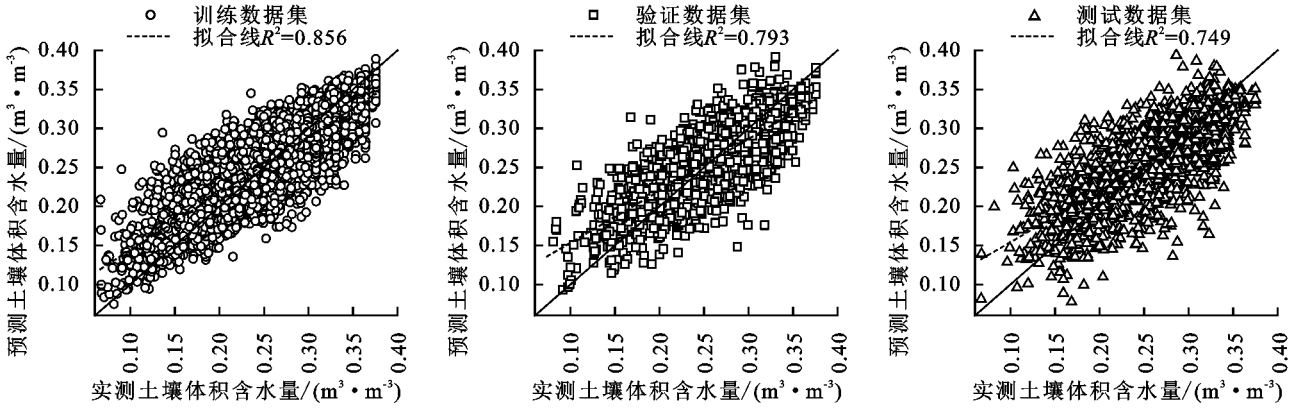

图 4　分站点建立神经网络模型的不同数据集拟合效果

为充分比较不同区域气象数据与土壤湿度数据的拟合效果，选择苏北沿海地区 58049（滨海）站点、淮北平原 58215（寿县）站点、长江三角洲平原 58356（昆山）站点和浙西北丘陵区的 58530（歙县）站点进行对比（站点位置见图 1）。4 个站点分别构建的 BP 神经网络模型的预测值与实测值的对比结果见图 5 和图 6。58049 站点的土壤水分时间变化较平稳，其训练、验证和测试数据集的预测精度均优于其他站点，此站点土壤水分与相对湿度和日照时间的 Pearson 相关系数较高（分别为 0.485 和 −0.422），且在 $P<0.05$ 水平显著。58356 站点的 3 个数据集的 RMSE 和 MAE 比其他站点稍大，并且土壤含水量波动较大，土壤水分与地表温度和相对湿度的相关性较高，且在 $P<0.05$ 水平显著（相关系数分别为 −0.479** 和 0.466**）。58215 站点和 58530 站点的拟合效果介于二者之间，2 个站点的土壤含水量变化均较稳定。其中，58215 站点位于内陆平原水网区，受地表水体影响，土壤水分变化较稳定，土壤水分与日照时间和地表温度的相关性分别为 −0.456 和 −0.396，且在 $P<0.05$ 水平显著；58530 站点位于低山丘陵区的林区，人类活动影响较小，气象因子中以 7 天累计降水量和日照时间为主导（相关系数分别为 0.478 和 −0.457，且在 $P<0.05$ 水平显著）。由此可见，不同地理位置站点土壤水分的主控气象因子不同，采用单一的定量关系很难准确表达大范围、长时序的土壤水分与气象因子的函数关系。

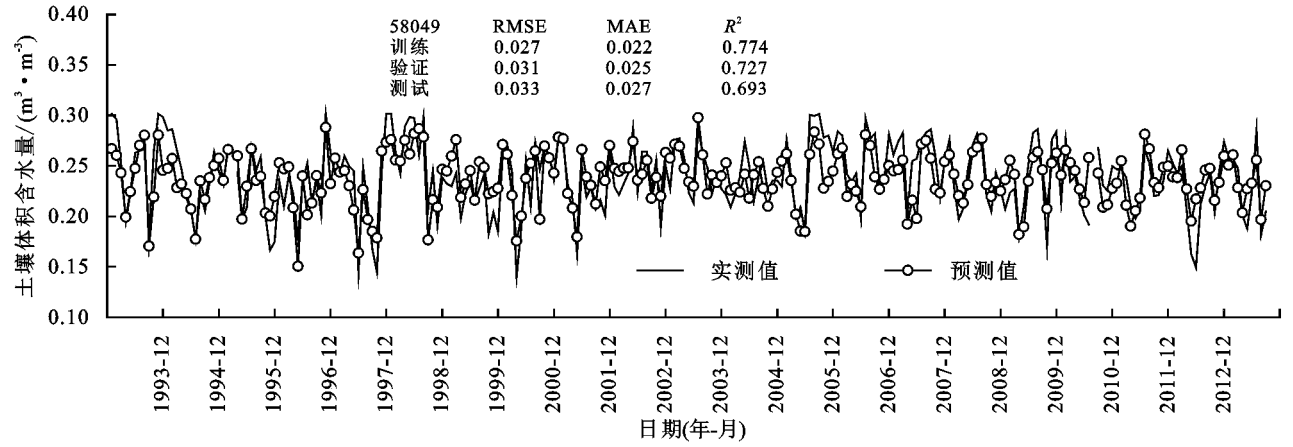

图 5　58049 站点建立的神经网络模型与实测值的对比案例

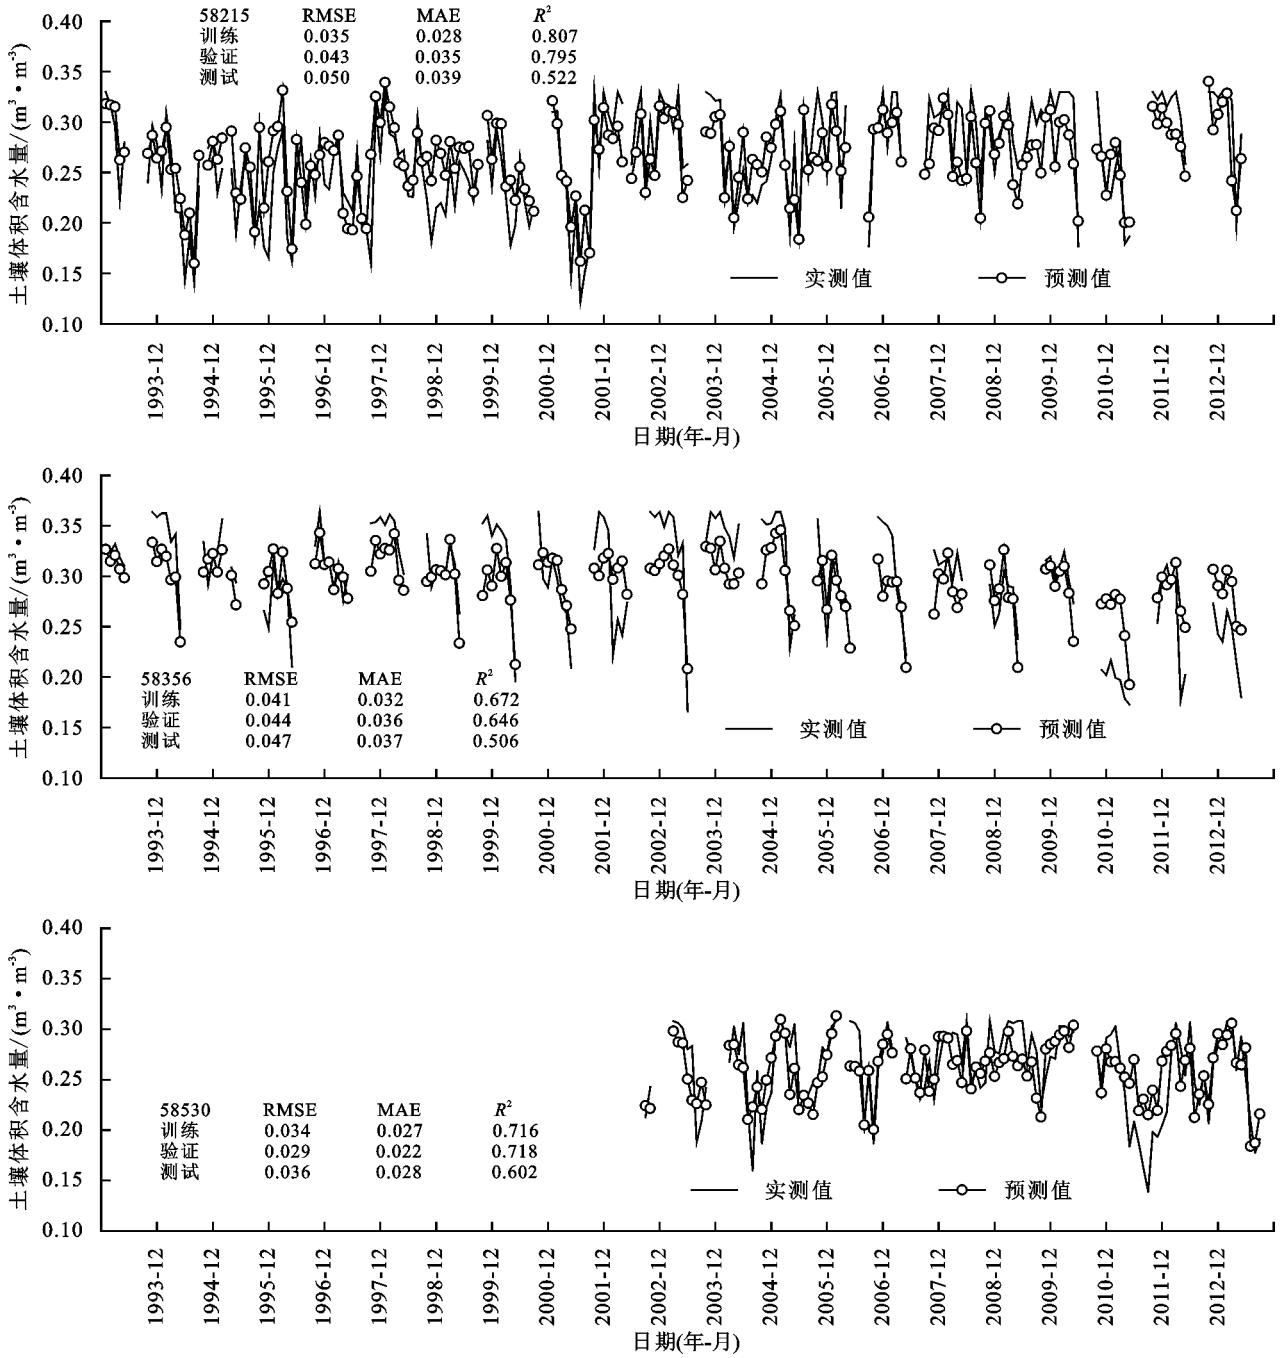

图 6 58215,58356,58530 站点建立的神经网络模型与实测值的对比案例

3 结 论

(1)基于主成分分析,将选取的 8 个气象因子降维处理,得到 4 个主成分。

(2)基于全部站点的土壤水分与 4 个主成分数据构建的单一线性模型精度低于单一 BP 神经网络模型,表明土壤水分和气象要素间存在着复杂的非线性关系。

(3)分站点构建的 BP 神经网络模型优于基于全部站点构建的单一 BP 神经网络模型,可能原因是不同站点所在地理位置不同,其土壤水分和气象因子间的关系也随之发生变化。

本研究的结果为土壤水分的时间变化预测提供了新思路,使得利用常规气象观测资料补充和延长长三角地区的站点监测土壤水分数据成为可能,同时为其他区域土壤水分时间序列的补充提供借鉴和参考。但由于数据的缺乏,本文仅研究了土壤水分与气象因子的关系,其他相关的影响因子对土壤水分的影响有待进一步研究;同时,此方法的普适性和稳定性需要其他地区的进一步补充和验证。

参考文献:

[1] 季劲钧,刘青,李银鹏.半干旱地区地表水平衡的特征和模拟[J].地理学报,2004,59(6):964-971.

[2] Seneviratne S I, Corti T, Davin E L, et al. Investigating

soil moisture-climate interactions in a changing climate: A review[J].Earth Science Reviews,2010,99(3/4):125-161.

[3] 范科科,张强,孙鹏,等.青藏高原地表土壤水变化、影响因子及未来预估[J].地理学报,2019,74(3):520-533.

[4] Zeng J Y, Li Z, Chen Q, et al. Evaluation of remotely sensed and reanalysis soil moisture products over the Tibetan Plateau using in-situ observations[J]. Remote Sensing of Environment,2015,163:91-110.

[5] 范科科,张强,史培军,等.基于卫星遥感和再分析数据的青藏高原土壤湿度数据评估[J].地理学报,2018,73(9):1778-1791.

[6] Hauser M, Orth R, Seneviratne S I. Role of soil moisture versus recent climate change for the 2010 heat wave in western Russia[J]. Geophysical Research Letters, 2016,43(6):2819-2826.

[7] Miralles D G, Teuling A J, Van Heerwaarden C C, et al. Mega-heat wave temperatures due to combined soil desiccation and atmospheric heat accumulation[J]. Nature Geoscience,2014,7(5):345-349.

[8] 薛晓萍,王新,张丽娟,等.基于支持向量机方法建立土壤湿度预测模型的探讨[J].土壤通报,2007,38(3):427-433.

[9] 朱青,廖凯华,赖晓明,等.流域多尺度土壤水分监测与模拟研究进展[J].地理科学进展,2019,38(8):1150-1158.

[10] 史舟,徐冬云,滕洪芬,等.土壤星地传感技术现状与发展趋势[J].地理科学进展,2018,37(1):79-92.

[11] Chen Y Y, Yang K, Qin J, et al. Evaluation of AMSR-E retrievals and GLDAS simulations against observations of a soil moisture network on the central Tibetan Plateau[J].Journal of Geophysical Research Atmospheres,2013,118(10):4466-4475.

[12] Liu Y Y, Dorigo W A, Parinussa R M, et al. Trend-preserving blending of passive and active microwave soil moisture retrievals[J].Remote Sensing of Environment,2012,123:280-297.

[13] 杨娜,刘良明,向大享,等.利用 BP 神经网络由特征气象要素预测土壤湿度[J].土壤通报,2011,42(6):1324-1329.

[14] Chen N, Li X Y, Šimůnek J, et al. Evaluating soil nitrate dynamics in an intercropping dripped ecosystem using HYDRUS-2D[J]. Science of the Total Environment,2020,718:1-13.

[15] Dang T D, Vu D T, Chowdhury A F M K, et al. A software package for the representation and optimization of water reservoir operations in the VIC hydrologic model[J]. Environmental Modelling and Software, 2020,126:104673.

[16] Chen M Y, Gassman P W, Srinivasan R, et al. Analysis of alternative climate datasets and evapotranspiration methods for the Upper Mississippi River Basin using SWAT within HAWQS[J]. Science of the Total Environment,2020,720:137562.

[17] 王振龙,高建峰.实用土壤墒情监测预报技术[M].北京:中国水利水电出版社,2006.

[18] 郭庆春,王素娟,何振芳.基于 BP 人工神经网络的土壤含水量预测模型的研究[J].山东农业科学,2012,44(12):11-15.

[19] 李彬楠,樊贵盛.基于支持向量机方法的土壤水分特征曲线预测模型[J].节水灌溉,2019(1):108-111,117.

[20] 李小刚,王静,马友华,等.基于 BP 神经网络的土壤墒情预测精度研究:以肥东县为例[J].土壤通报,2017,48(2):292-297.

[21] 冯徽徽,刘元波,杨风亭.高植被覆盖区 AMSR－E 土壤水分数据校准方法[J].土壤通报,2014,45(4):816-822.

[22] 王青青,张珂,叶金印,等.安徽省土壤湿度时空变化规律分析及遥感反演[J].河海大学学报(自然科学版),2019,47(2):24-28.

[23] 辛强,李兆富,李瑞娟,等.基于温度植被干旱指数的华东地区 AMSR-E 土壤水分数据的空间降尺度研究[J].农业现代化研究,2016,37(5):956-963.

[24] 崔园园,张强,覃军,等.CLDAS 融合土壤湿度产品在东北地区的适用性评估及订正[J].中国农业气象,2019,40(10):660-668.

[25] Zhang Y G, Schaap M G, Zha Y Y. A high-resolution global map of soil hydraulic properties produced by a hierarchical parameterization of a physically based water retention model[J]. Water Resources Research, 2018,54(12):9774-9790.

[26] 袁淑杰,何兴潼,谷晓平,等.贵州喀斯特区域土壤湿度持续下降时期气象要素对土壤湿度影响研究[J].土壤通报,2018,49(2):320-328.

[27] 盛承懋.应用回归分析[M].上海:上海科学技术文献出版社,1989.

[28] 刘学勤,何力春,奥小平.宜林荒山春季土壤含水率与气象因子的相关分析[J].北京林业大学学报,1993,15(3):26-33.

[29] 孙倩倩,刘晶淼,梁宏.东北地区土壤湿度的区域性预报模型研究[J].自然资源学报,2014,29(6):1065-1075.

[30] 陈昌华,谭俊,尹健康,等.基于 PCA－RBF 神经网络的烟田土壤水分预测[J].农业工程学报,2010,26(8):85-90.