

DOI:10.3876/j.issn.1000-1980.2019.02.004

安徽省土壤湿度时空变化规律分析及遥感反演

王青青^{1,2}, 张珂^{1,2}, 叶金印³, 李致家²

(1. 河海大学水文水资源与水利工程科学国家重点实验室, 江苏 南京 210098;
2. 河海大学水文水资源学院, 江苏 南京 210098; 3. 中国气象局气象干部培训学院安徽分院, 安徽 合肥 230031)

摘要: 为获取安徽省的土壤湿度时空信息, 采用克里金法将站网实测多层土壤湿度数据插值为网格数据, 分析其时空变化特征; 进而建立遗传算法优化的 BP(back propagation)神经网络模型进行土壤湿度反演。该模型以风云 3B 卫星的亮温数据为主要输入, 训练后对该模型验证并进行预测。结果表明: 安徽省土壤湿度月均值波动较频繁, 淮北平原和大别山区较其他区域干燥; 随着深度的增加, 土壤湿度增大且季节和空间差异变小; 所有分区平均模拟值与实测值的日序列相关性达到 0.605, 均方根误差为 $0.056\text{ m}^3/\text{m}^3$, 说明该模型能够较好地反演安徽省土壤湿度。
关键词: 安徽省; 土壤湿度; 时空变化; 人工神经网络; 微波遥感; 土壤湿度卫星反演
中图分类号: S152.7 **文献标志码:** A **文章编号:** 1000-1980(2019)02-0114-05

Spatiotemporal analysis and remote sensing retrieval of soil moisture across Anhui Province, China

WANG Qingqing^{1,2}, ZHANG Ke^{1,2}, YE Jinyin³, LI Zhijia²

(1. State Key Laboratory of Hydrology-Water Resources and Hydraulic Engineering, Hohai University, Nanjing 210098, China;
2. College of Hydrology and Water Recourses, Hohai University, Nanjing 210098, China;
3. Anhui Branch of China Meteorological Administration Training Centre, Hefei 230031, China)

Abstract: To obtain the spatiotemporal characteristics of soil moisture in Anhui Province, the Kriging method was firstly used to interpolate the in-situ observed and multilayer soil moisture to gridded data. Then, the spatiotemporal variability of soil moisture across this region was analyzed. A Back Propagation (BP) neural network optimized by the genetic algorithm was established to retrieve the soil moisture using the brightness temperature measured by the Fengyun 3B satellite. The results show that soil moisture across Anhui Province shows high temporal fluctuations. And, the soil moisture in the Huaibei plain and the Dabie Mountains is lower than the other regions. As depth becomes deeper, soil moisture has a higher value with lower seasonal and horizontal variability. The correlation between retrieved and observed daily gridded values across the five sub-regions is 0.605, while the corresponding root mean square error is $0.056\text{ m}^3/\text{m}^3$. Clearly, the proposed retrieval algorithm is able to capture the spatiotemporal variability of soil moisture in Anhui Province.

Key words: Anhui Province; soil moisture; spatiotemporal variability; artificial neural network; remote sensing; satellite retrieval of soil moisture

基金项目: 国家重点研发计划(2016YFC0402701); 国家自然科学基金(518679067); 江苏省杰出青年基金(BK20180022)
作者简介: 王青青(1993—), 女, 硕士研究生, 主要从事水文物理规律模拟及水文预报研究。E-mail: qingqingwang@hhu.edu.cn
通信作者: 张珂, 教授。E-mail: kzhang@hhu.edu.cn
引用本文: 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): 114-118.
WANG Qingqing, ZHANG Ke, YE Jinyin, et al. Spatiotemporal analysis and remote sensing retrieval of soil moisture across Anhui Province, China[J]. Journal of Hohai University(Natural Sciences), 2019, 47(2): 114-118.

土壤湿度是水循环过程的重要状态变量,也是地表水和地下水的关联者,在生态评估、农业发展以及灾害预警等方面起着重要作用,因此研究土壤湿度的时空变化特征及大范围监测十分必要^[1-2]。土壤湿度的获取方法主要有站点监测法、模型模拟和遥感反演^[3]。站点监测方法精度高,能获取不同深度的数据,但单点监测限制了其测量范围^[4]。模型模拟则是根据水分平衡进行推演,能够快速地获取面上信息,但对输入要求较多,参数难以确定^[3]。基于人工神经网络的土壤湿度遥感反演,无需明确具体物理关系,模型“黑匣”式的映射既能减少参数选取的误差,又能具备遥感宏观动态的特点。目前,此方面研究已有一定进展^[5-6]。

笔者采用克里金插值方法获得安徽省实测土壤湿度网格数据,并探究其时空变化规律。在此基础上,利用遥感数据和人工神经网络来模拟土壤湿度,建立反演模型,该模型结合了实测数据精度高、神经网络参数少、遥感数据易获得、输入数据类型少的优点。

1 研究区概况与数据来源

1.1 研究区概况

安徽省位于中国东部,面积为 14 万 km²。长江和淮河穿过安徽省,把整个地区分为平原、丘陵和山区。淮河以北为暖温带半湿润季风气候,以南为亚热带湿润季风气候。其年平均气温为 14~17℃,年降水量为 750~1 700 mm^[7]。安徽省分为 5 个区域(图 1),耕地为主要的土地利用类型,集中在安徽北部和中部;其次为森林,集中在南部和西南部。

1.2 数据来源及预处理

1.2.1 土壤湿度实测数据

土壤湿度实测数据来自安徽气象局的土壤湿度观测网,由 85 个自动土壤湿度站组成(图 1)。观测采用 DZN2(GStar-I)型自动土壤水分观测仪,通过转化测量的土壤相对介电常数获取体积土壤含水率。观测在 8 个深度进行,即 10 cm、20 cm、30 cm、40 cm、50 cm、60 cm、80 cm、100 cm。本文选取 10 cm、30 cm、50 cm、80 cm 土壤湿度日值作为研究对象,时间为 2012 年 1 月 1 日至 2016 年 8 月 19 日,其他数据时间范围与土壤湿度一致。采用克里金插值方法^[8-9]将土壤湿度站点数据插值为空间分辨率为 0.05°和 0.25°的网格数据,其中前者使用 4 层深度数据来分析时空变化特征,后者使用表层数据训练反演模型。

1.2.2 卫星数据

风云三号(FY-3)气象卫星是我国的第二代极轨气象卫星。研究使用 FY-3B 亮温升轨数据,处理为空间分辨率为 0.25°的日数据。在此基础上,计算指数 I_1 和 I_2 ^[5]:

$$I_1(t,i,j)=\frac{T_b(t,i,j)-T_b^{\min}(i,j)}{T_b^{\max}(i,j)-T_b^{\min}(i,j)} \tag{1}$$

$$I_2(t,i,j)=S_{T_b}^{\min}(i,j)+[S_{T_b}^{\max}(i,j)-S_{T_b}^{\min}(i,j)]I_1(t,i,j) \tag{2}$$

式中: $T_b(t,i,j)$ ——网格 (i,j) 在 t 时的亮温,K; $T_b^{\max}(i,j)$ 、 $T_b^{\min}(i,j)$ ——网格 (i,j) 在该时间序列中的亮温最大值、最小值,K; $S_{T_b}^{\max}(i,j)$ ——网格 (i,j) 达到亮温最大值时的土壤湿度值,m³/m³; $S_{T_b}^{\min}(i,j)$ ——网格 (i,j) 达到亮温最小值时的土壤湿度值,m³/m³。

1.2.3 其他数据

研究采用归一化植被指数(NDVI)提高土壤湿度的反演效果。NDVI 数据来自 MODIS 的 MYD13C1 产品,将原有的 16 d、0.05°数据处理为 0.25°、逐日数据。研究使用的温度和雪深数据来自于 Global Land Data Assimilation System (GLDAS)^[10]的 NOAH025_3H.2.1 产品,空间分辨率为 0.25°,时间分辨率为 3 h,取平均值处理为日数据。

2 建立模型

2.1 建模方法

人工神经网络自 20 世纪 80 年代迅速兴起,是一种模仿人脑行为的全新方法,能够通过训练得到与参考




图1 安徽省分区示意图

Fig.1 Zoning map of Anhui Province

数据特性接近的模型,因此可以运用到水文预报中^[11-12]。在多类别的人工神经网络中,BP神经网络较为经典,它是一种由信息正向传播和误差反向传播组成的多层前馈网络^[13-14]。本文运用成熟的BP神经网络建模,借鉴前人经验及实际测试确定模型具体结构。

2.2 反演模型的建立

通过测试,模型输入数据选择10个通道的亮温和 I_2 指数以及NDVI,共21个变量。模型训练的参考数据为插值后的 0.25° 实测土壤湿度数据。选择2012—2014年的数据作为训练集,该集合具有完整的年内变化特征。其中随机选取60%的数据用于训练模型,20%用于验证,20%用于测试。模型训练完成后,使用2015—2016年的数据进行预测和评估。数据集在使用前进行了如下筛选:去除冻结土壤,即土壤温度小于274 K;去除雪地,即雪深大于1 mm;去除水体,包括湖泊和水系^[6, 15]。所有类型数据在模型中使用时已经进行了归一化处理。

增加隐含层层数不能保证提高预测精度^[16],3层BP网络具有较强的非线性映射能力,能够以任意精度逼近一个连续函数,因此模型采用3层网络。目前常用试错法和经验公式法确定隐含层神经元数,研究在对数据集进行测试后,将神经元数初设为10个,该数目能够使模型较好地模拟土壤湿度变化特征,确定最佳输入模型后再根据输入重新调整神经元数。

输入层和隐含层的激励函数使用tansig函数,输出函数为purelin函数,训练函数为trainlm。学习速率为0.01,训练目标为0.001。采用遗传算法对网络的权值进行优化。

3 结果分析

3.1 时空变化特征

图2(a)为安徽省4个深度土壤湿度的月均值变化情况,从时间上看,土壤湿度具有较大的时间变化和波动,各层深度土壤湿度随时间变化的特点基本一致。土壤深度越大,土壤湿度越大,波动越小,月均值变化差异变小且逐渐滞后。降水和蒸发是影响土壤湿度的主要气象因素,其作用会随土壤深度的增加而减弱,因此表层土壤湿度比深层变化较大;同时,水分在垂直运动和交换上的影响使得深层土壤湿度的月均值特征比浅层滞后。图2(b)为安徽省各分区表层土壤湿度的多年月均值变化情况,各分区表层土壤湿度没有“单峰”季节性而是波动较为频繁,总体变化一致但局部有所区别,2月、3月、7月和9月的土壤湿度明显较大,10月的土壤湿度最小,这可能与该地区的气候条件相关。




图2 土壤湿度时间变化曲线

Fig.2 Time series of monthly average soil moisture of the whole region in four soil depths

图3为安徽省各深度土壤湿度多年日均值空间分布,从水平空间来看,淮北平原的土壤湿度较小,大别山区次之,江淮丘陵和沿江平原土壤湿度较大。水平空间上的分布不均匀与气候条件及地理条件有较大的相关性,淮北平原气候较为干旱,大别山区的土壤孔隙度相对较小,因此2个区域容易呈现较干现象;江淮丘陵和沿江平原处于亚热带湿润季风气候,因此较为湿润。从垂直空间来看,随着深度的增加,土壤湿度在空间上分布趋于均匀,各区域的干湿差距减小。这表明土壤湿度随着深度的增加呈现更加稳定的状态,与图2结论一致。

3.2 模型反演结果

经测试,发现增加指数 I_2 和NDVI作为输入,模型反演结果均有所改善。比较以10TB、10TB-NDVI、10TB- $10I_2$ 和10TB- $10I_2$ -NDVI为输入的模型,选择效果最好的模型即输入为10TB- $10I_2$ -NDVI的模型作为反演模型,重新确定新的神经元数为12个。




图 3 安徽省各深度土壤湿度多年日均值空间图

Fig. 3 Spatial maps of multi-year average daily soil moisture in four depths across Anhui Province

图 4(a)(b)分别为安徽省实测与反演土壤湿度多年日均值空间图。在大部分区域模型能够较好地模拟实测值,存在部分地区低估现象:两者在淮北平原都较为干旱,在江淮丘陵和沿江平原都较为湿润,在大别山区和皖南山区对实测土壤湿度模拟偏低,这可能是森林覆盖影响了遥感模拟效果。此外,大别山区站点数较少,土壤湿度动态变化监测不足,可能是导致大别山区反演误差较大的原因之一。图 4(c)为实测与反演土壤湿度的日值相关性空间图。安徽省大部分地区的相关系数在 0.4 以上,占到全省的 71.12%,相关系数在 0.5 以上的地区占到了 47.06%。图 4(d)为实测土壤湿度与模型反演土壤湿度的日值均方根误差图。安徽省大部分地区的均方根误差在 $0.065\text{ m}^3/\text{m}^3$ 以下,占到全省的 65.78%。可以看出,淮北平原相关性和均方根误差均较小,这可能是由于淮北平原土壤湿度较小,因此产生的均方根误差也较小,而其常年变化不大导致模型模拟的不确定性较大,故其相关性相对较差。




图 4 实测与反演值多年日值空间图

Fig. 4 Spatial maps of multi-year average daily observed soil moisture

由图 5 可知,实测值与反演值基本都在 $0.20 \sim 0.45\text{ m}^3/\text{m}^3$ 内变化。所有分区平均模拟值与实测值的日序列相关性为 0.605,均方根误差为 $0.056\text{ m}^3/\text{m}^3$ 。因此,本文模型能够较好地掌握安徽省实测土壤湿度的变化情况。

4 结 论

a. 安徽省土壤湿度随时间波动较大,各区月均值波动较为频繁,各层深度土壤湿度时间变化特征基本一致,随着深度增加,出现土壤湿度变大、土壤湿度时空差异变小、时间变化逐渐滞后的现象;由于受气候和地理条件的影响,表层土壤湿度空间分布较不均匀,淮北平原的土壤湿度较小,大别山区次之,江淮丘陵和沿江平原土壤湿度较大,随着深度的增加,各区域的干湿差距减小,在深层土壤湿度状况基本一致。

b. 建立的 BP 神经网络模型,以亮温数据作为主要输入,实测插值网格数据作为参考输出,训练得到的 10TB-10I₂-NDVI 模型模拟效果较好,具有输入易得、参数简单等优点,其预测结果能够较好地反映土壤湿度的时空变化特征。

此外,研究中站点数据有限,插值到网格的过程存在尺度效应误差;对于土壤湿度较小的地区,反演效果




图 5 5 个分区土壤湿度实测与反演数据日均值

Fig. 5 Scatter plot of daily average observed soil moisture of the five zones versus the retrieved values

如何提高需要深入研究。

参考文献:

[1] 刘荣华, 张珂, 晁丽君, 等. 基于多源卫星观测的中国土壤湿度时空特征分析 [J]. 水科学进展, 2017, 28(4): 479-487. (LIU Ronghua, ZHANG Ke, CHAO Lijun, et al. Analysis of spatiotemporal characteristics of surface soil moisture across China based on multi-satellite observations[J]. Advances in Water Science, 2017, 28(4): 479-487. (in Chinese))

[2] 王逸男, 安如, 尤加俊, 等. CCI 土壤湿度产品在中国区的降尺度与融合研究 [J]. 河海大学学报(自然科学版), 2018, 46(3): 196-202. (WANG Yinan, AN Ru, YOU Jiajun, et al. Downscaling and merging of the CCI soil moisture product over China [J]. Journal of Hohai University (Natural Sciences), 2018, 46(3): 196-202. (in Chinese))

[3] 向怡衡, 张明敏, 张兰慧, 等. 祁连山区不同植被类型上的 SMOS 遥感土壤水分产品质量评估 [J]. 遥感技术与应用, 2017, 32(5): 835-843. (XIANG Yiheng, ZHANG Mingmin, ZHANG Lanhui, et al. Validation of SMOS soil moisture products on different vegetation types in Qilian Mountain[J]. Remote Sensing Technology and Application, 2017, 32(5): 835-843. (in Chinese))

[4] 马春芽, 王景雷, 黄修桥. 遥感监测土壤水分研究进展 [J]. 节水灌溉, 2018(5): 70-74. (MA Chunya, WANG Jinglei, HUANG Xiuqiao. Progress of soil moisture monitoring by remote sensing[J]. Water Saving Irrigation, 2018(5): 70-74. (in Chinese))

[5] RODRÍGUEZ-FERNÁNDEZ N J, AIRES F, RICHAUME P, et al. Soil moisture retrieval using neural networks: application to SMOS [J]. IEEE Transactions on Geoscience & Remote Sensing, 2015, 53(11): 5991-6007.

[6] KOLASSA J, REICHLE R H, LIU Q, et al. Estimating surface soil moisture from SMAP observations using a Neural Network technique [J]. Remote Sensing of Environment, 2018, 204: 43-59.

[7] 聂兵, 沈非, 徐光来, 等. 安徽省近 50 年降水时空变化分析 [J]. 安徽师范大学学报(自然科学版), 2017, 40(6): 574-579. (NIE Bing, SHEN Fei, XU Guanglai, et al. Analysis of temporal-spatial change in Anhui Province in recent 50 years[J]. Journal of Anhui Normal University (Natural Science), 2017, 40(6): 574-579. (in Chinese))

[8] 林金煌, 林广发. 福建省降水空间插值方法比较与区域分布特征研究 [J]. 海南师范大学学报(自然科学版), 2015, 28(1): 61-65. (LIN Jinhuang, LIN Guangfa. Comparison of spatial interpolation methods for precipitation and regional distribution characteristic in Fujian Province [J]. Journal of Hainan Normal University (Natural Science), 2015, 28(1): 61-65. (in Chinese))

[9] 戴培培, 靖常峰, 杜明义. 基于雨量计的城区降雨插值不确定性分析 [J]. 人民黄河, 2015, 37(4): 38-42. (DAI Peipei, JING Changfeng, DU Mingyi. Uncertainty analysis of urban rainfall spatial interpolation based on gauges data [J]. Yellow River, 2015, 37(4): 38-42. (in Chinese))

[10] 钱安, 易爽, 孙广通, 等. GLDAS_NOAH_M.2.1 水文模型在青藏高原的适用性分析 [J]. 大地测量与地球动力学, 2018, 38(3): 254-259. (QIAN An, YI Shuang, SUN Guangtong, et al. GLDAS_NOAH_M.2.1 hydrological model and its application analysis in the Qinghai-Tibet Plateau [J]. Journal of Geodesy and Geodynamics, 2018, 38(3): 254-259. (in Chinese))

[11] 韩通, 李致家, 刘开磊, 等. 山区小流域洪水预报实时校正研究 [J]. 河海大学学报(自然科学版), 2015, 43(3): 208-214. (HAN Tong, LI Zhijia, LIU Kailei, et al. Research on real-time correction method of flood forecasting in small mountain watershed [J]. Journal of Hohai University (Natural Sciences), 2015, 43(3): 208-214. (in Chinese))

[12] 卢文喜, 杨忠平, 李平, 等. 基于改进 BP 算法的地下水动态预测模型 [J]. 水资源保护, 2007, 23(3): 5-8. (LU Wenxi, YANG Zhongping, LI Ping, et al. Dynamic prediction model of groundwater level based on improved BP algorithm [J]. Water Resources Protection, 2007, 23(3): 5-8. (in Chinese))

[13] 徐伟, 董增川, 付晓花, 等. 基于 BP 人工神经网络的河流生态健康预警 [J]. 河海大学学报(自然科学版), 2015, 43(1): 54-59. (XU Wei, DONG Zengchuan, FU Xiaohua, et al. Early warning of river ecosystem health based on BP artificial neural networks [J]. Journal of Hohai University (Natural Sciences), 2015, 43(1): 54-59. (in Chinese))

[14] 李培都, 司建华, 冯起, 等. 疏勒河年径流量变化特征分析及模拟 [J]. 水资源保护, 2018, 34(2): 52-60. (LI Peidu, SI Jianhua, FENG Qi, et al. Analysis and simulation on annual runoff variation characteristics of Shule River [J]. Water Resources Protection, 2018, 34(2): 52-60. (in Chinese))

[15] RODRÍGUEZ-FERNÁNDEZ N J, KERR Y H, SCHALIE R V D, et al. Long term global surface soil moisture fields using an SMOS-trained neural network applied to AMSR-E data [J]. Remote Sensing, 2016, 8: 959-985.

[16] 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. (LI Xiaogang, WANG Jing, MA Youhua, et al. Research on soil moisture forecast model based on BP neural network-a case study at Feidong County [J]. Chinese Journal of Soil Science, 2017, 48(2): 292-297. (in Chinese))