

陕西省月用水量预测方法研究

陈星¹, 沈紫菡¹, 许钦^{2,3,4}, 刘睿佳¹, 蔡晶⁴

(1. 河海大学水文水资源学院, 江苏南京 210098; 2. 河海大学水灾害防御全国重点实验室, 江苏南京 210098; 3. 河海大学长江保护与绿色发展研究院, 江苏南京 210098; 4. 南京水利科学研究院水文水资源研究所, 江苏南京 210029)

摘要: 基于国家水资源管理信息系统的月用水量数据分析, 选用 ARIMA 模型、BP 神经网络模型以及经过遗传算法(GA)优化的 BP 神经网络模型(GA-BP 神经网络模型)进行月用水量模拟。在构建 BP 神经网络模型过程中, 通过多源社会经济数据的整合与分析, 采用平均影响值算法(MIV)和皮尔逊相关系数联合方法筛选月用水量的关键影响因子。研究表明, 三种模型在陕西省月用水量预测中均表现出较高的精度, 其中 GA-BP 神经网络模型的预测精度最高。为进一步验证影响因子对模拟结果的影响, 采用不同方法筛选影响因子作为 GA-BP 神经网络模型的输入, 模拟结果表明, MIV 和皮尔逊相关系数联合方法提高了影响因子的选取精度, 能够有效提升 GA-BP 神经网络模型的模拟性能。

关键词: 月用水量预测; ARIMA 模型; 遗传算法; 神经网络模型; 因子筛选; 陕西省

中图分类号: TV213.4

文献标志码: A

文章编号: 1006-7647(2025)01-0073-06

Research on monthly water consumption prediction methods in Shaanxi Province// CHEN Xing¹, SHEN Zihan¹, XU Qin^{2,3,4}, LIU Ruijia¹, CAI Jing⁴(1. College of Hydrology and Water Resources, Hohai University, Nanjing 210098, China; 2. The National Key Laboratory of Water Disaster Prevention, Hohai University, Nanjing 210098, China; 3. Yangtze Institute for Conservation and Development, Hohai University, Nanjing 210098, China; 4. Hydrology and Water Resources Department, Nanjing Hydraulic Research Institute, Nanjing 210029, China)

Abstract: Based on analysis of the monthly water consumption data from the national water resource management information system, the ARIMA model, the BP neural network model and the BP neural network model optimized by the genetic algorithm (the GA-BP neural network model) were used for monthly water consumption simulation. In the process of constructing the BP neural network model, the combined method of mean impact value algorithm (MIV) and Pearson correlation coefficients was used to screen the key influencing factors of monthly water consumption through the integration and analysis of multi-source socio-economic data. The research results show that all three models exhibit relatively high accuracy in the monthly water consumption prediction in Shaanxi Province, among which the GA-BP neural network model has the highest prediction accuracy. To further verify the impact of influencing factors on the simulation results, different methods were used to screen the influencing factors as the input of the GA-BP neural network model. The simulation results indicate that the combined method of MIV and Pearson correlation coefficients improves the selection accuracy of influencing factors and can effectively enhance the simulation performance of the GA-BP model.

Key words: monthly water consumption prediction; ARIMA model; genetic algorithm; neural network model; factor screening; Shaanxi Province

我国降水和水资源的年内分配与实际用水需求存在明显的时间差异, 这种差异给水资源管理带来挑战, 因此需要通过水资源的合理配置来实现区域可持续发展^[1]。在这一背景下, 用水量预测成为科学调配水资源的重要依据^[2]。随着社会经济的快速发展和人民生活水平的提高, 传统的年尺度用水

量预测方法在时效性和精细化上已无法满足日益动态和复杂的水资源管理要求。月尺度的用水量预测不仅有助于提高水资源利用效率, 还能更灵活地应对不同季节和特定时段的用水波动, 推动水资源精细化管理和调度, 提高水资源集约利用水平^[3], 为实现区域经济增长和社会进步奠定坚实基础。

基金项目: 国家自然科学基金项目(52209031); 中央级公益性科研院所基本科研业务费专项资金项目(Y522001, Y522018, Y520009); 山东省重点研发计划项目(2023CXGC010905)

作者简介: 陈星(1980—), 女, 副教授, 博士, 主要从事水文学及水资源研究。E-mail: 77574471@qq.com

通信作者: 沈紫菡(1999—), 女, 硕士研究生, 主要从事水文学及水资源研究。E-mail: 2415028035@qq.com

用水量预测方法主要包括定额法、时间序列法和相关分析法等。定额法主要根据确定的用水指标或定额,对地区或城市未来时期的年用水量进行预测^[4];时间序列法利用历史用水数据的时序性构建预测模型^[5-6];相关分析法则基于用水量主要影响因素的历史数据来构建预测模型^[7]。Niknam 等^[8]验证了不同用水量预测方法的适用性,包括人工神经网络、回归分析、启发式和元启发式算法、随机森林、传统时间序列和动态系统,结果表明,人工神经网络在复杂问题的建模和预测方面表现突出。王浏琳等^[9]在分析南京市用水量现状的基础上,采用灰色预测 GM(1,1)模型与 Elman 神经网络的组合模型预测了用水量。周宇茗等^[10]采用 ARMA、灰色 GM(1,1)和 BP 神经网络模型,建立省级行政区划、流域、地理大区 3 种尺度的年用水总量预测模型,对模型优选结果进行了统计分析。

目前,关于月用水量预测的相关研究尚处于初始阶段。例如:Ristow 等^[11]采用指数平滑状态空间模型和 ARIMA 模型进行了城市月用水量预测,发现 ARIMA 模型预测精度更高,应用效果更好;Zubaidi 等^[12]采用人工神经网络优化的回溯搜索算法预测了气象条件和人口增长影响下的月用水量。月用水量受多种因素影响,数据波动较大,具有更强的不确定性^[13-14]。此外,月用水量数据积累时间短,统计分析难度大,进一步增加了准确预测的难度。随着信息化和智能化的发展,大数据时代的到来为水利数据提供了更精细的采集频率^[15],为月用水量预测研究提供了更丰富、更全面的数据支持。在新数据源的支撑下,本文综合稳定性、灵活性、可扩展性、计算效率等多个因素选择月用水量预测模型,探索不同模型的预测效果与适用性。

陕西省地处中国内陆腹地,位于黄河中游,水资源总量匮乏且年内分配不均,随着社会经济发展规模的扩大,水资源的供需矛盾愈发突出。本文以陕西省为研究区,选用基于时间序列法(ARIMA 模型)和基于相关分析法(BP 神经网络模型、GA-BP 神经网络模型)的月用水量预测模型,研究小样本数据集情景下月用水量预测模型的表现,以期为水资源精细化管理提供支撑。

1 研究区概况与数据来源

1.1 研究区概况

陕西省位于黄河、长江两大水系交汇地带,总面积 20.56 万 km²,地处湿润与干旱气候区的交界地带,具有明显的大陆性气候特征。陕西省年均降水量为 656 mm,水资源相对匮乏,人均水资源占有量

为全国平均水平的 52%。2020 年,陕西省实现生产总值 26 181.86 亿元,比上年增长 2.2%。农业用水占据各部门用水量的主导地位,共 55.6 亿 m³,占总用水量的 61.4%,其次是生活用水和工业用水,分别占总用水量的 14.97% 和 12%。随着陕西省经济总量的不断扩大,用水需求持续增加,导致水资源刚性约束日益趋紧。为了更好地利用水资源,提高水资源调配与高效利用能力变得尤为重要,因此开展月用水量预测的研究对于陕西省的水资源管理和经济可持续发展具有重要意义。

1.2 数据来源

月用水量数据源自国家水资源管理信息系统。该系统在全国范围内的水资源利用数据进行实时监测与收集。系统于 2015 年初步建成并投入使用,建成初期监测点覆盖尚不全面,导致 2015 年和 2016 年用水量数据序列完整性不足,为确保数据的准确性和可靠性,本文选取 2017—2020 年的月用水量数据作为有效数据集。

气象与社会经济相关数据来自多个数据源,包括国家水资源管理信息系统、陕西省统计局官网的月报和季报、政务服务查询平台、前瞻数据库、行业研究数据库等以及其他网络大数据。重点选取与月用水量相关的社会经济发展指标,整合了平均气温、降水量、人口、居民消费价格指数、居民人均可支配收入等 15 个影响因子(详见表 1)的月指标值。其中,GDP 数据为季度值,采用基于计量经济学和统计分析的 EViews 软件转换为月数据。考虑数据来源的复杂性和多元性,选择陕西省统计年鉴权威数据作为参考,与月数据累加的年值进行质量检验,以确保其可信度。由此建立月用水量影响因子月数据集,为后续研究提供数据支撑。

表 1 城市月用水量影响因子分类与指标初集

类别	影响因子初集
气候条件	月平均气温、月降水量
社会因素	人口、居民消费价格指数、居民人均可支配收入、居民人均消费支出、人均公园绿地面积、发电量
经济因素	GDP、第一产业增加值、第二产业增加值、第三产业增加值、农林牧渔业总产值、粮食总产量、有效灌溉面积

2 研究方法

选取基于时间序列法的 ARIMA 模型,以及基于相关分析法的 BP 神经网络模型和 GA-BP 神经网络模型作为预测模型。ARIMA 模型是一种广泛应用于非平稳时间序列分析的时间序列模型,可以分析时间序列数据的长期趋势和周期性变动,结构简单,稳定性高,具有较高的灵活性和参数可解释性^[16]。BP 神经网络是一种按照误差逆向传播算法训练的

多层前馈神经网络,可以实现任意的非线性映射,对处理信息含糊、不完整等情况有较强的适应性^[17]。GA-BP神经网络采用遗传算法(genetic algorithm, GA)对BP神经网络进行优化,提高其全局搜索能力,便于找到最优的权值和阈值,过程中不需要进行误差的反向传播,从而简化了算法形式^[17]。

2.1 基于时间序列法的预测模型

ARIMA模型包括自回归(AR)项、差分(I)项和移动平均(MA)项^[18]。采用2017—2019年陕西省月用水量数据构建时间序列,对原始数据进行 d 阶差分处理,得到平稳时间序列,并进一步确定参数模型的自回归项 p 和滑动平均阶数 q 。利用SPSS软件构建了ARIMA(2,1,0)模型并进行决定系数 R^2 检验和残差的白噪声检验。模型的 R^2 值为0.972,说明拟合效果好。残差的白噪声检验是为了检验模型是否已经充分利用了原始数据的有效信息。残差的Ljung-Box检验 P 值为0.988,大于0.05;自相关系数(autocorrelation function, ACF)图和偏自相关系数(partial autocorrelation function, PACF)图均在标准差置信区间内,说明残差随阶数变化没有显著的自相关性与偏自相关性。

2.2 基于相关分析法的预测模型

2.2.1 影响因子筛选

月用水量的影响因子众多,包括自然地理、气候、人口、经济规模和结构、政府政策等多种因素^[19]。根据陕西省实际情况,将影响因子分为三大类,根据影响机理确定月用水量的影响因子初集(表1)。

影响因子筛选的本质是降维,而平均影响值(mean impact value, MIV)算法是神经网络对输入变量进行降维的最好方法之一^[20]。MIV能够反映输入变量对输出变量的影响,保留了对预测结果影响较大的因子,但是没有考虑保留影响因子之间的信息重叠对预测结果的扭曲作用。因此选择MIV绝对值较大的影响因子开展皮尔逊相关性分析,并引入病态指数测度影响因子之间的信息重叠水平,得到最终的影响因子作为模型输入变量。若病态指数不大于10,则说明影响因子之间没有多重共线性,筛选完毕;若病态指数大于10,则需要进行皮尔逊相关性分析,剔除影响因子,并计算剩余影响因子的病态指数,直至病态指数不大于10。

通过MIV算法对陕西省月用水量影响因子进行分析,初步剔除MIV值小于0.030的影响因子,得到5个影响因子,即月平均气温(0.468)、第二产业增加值(0.290)、第三产业增加值(0.072)、居民人均可支配收入(0.039)和发电量(0.030)。其相关系数矩阵的最大特征值为3.234,最小特征值为

0.0002,病态指数为123.680,显著性大于10。说明存在较高的信息重叠,有必要剔除信息重叠程度较高的影响因子。对这5个影响因子进行皮尔逊相关性分析,得到相关性矩阵(表2)。由表2可知,第三产业增加值和居民人均可支配收入的皮尔逊相关性绝对值最大,为0.994;由于居民人均可支配收入的MIV值较小,因此剔除该因子。接着求出剩余影响因子的病态指数为11.621,继续对剩余影响因子进行剔除,直到病态指数小于10。最终得到月用水量预测的关键影响因子:月平均气温、第二产业增加值和发电量。

表2 陕西省月用水量影响因子皮尔逊相关性矩阵

影响因子	月平均气温	第二产业增加值	第三产业增加值	居民人均可支配收入	发电量
月平均气温	1.000	0.061	0.049	0.042	-0.285
第二产业增加值	0.061	1.000	0.982	0.958	0.436
第三产业增加值	0.049	0.982	1.000	0.994	0.462
居民人均可支配收入	0.042	0.958	0.994	1.000	0.467
发电量	-0.285	0.436	0.462	0.467	1.000

2.2.2 BP神经网络模型

BP神经网络采用梯度下降法,进行误差反向传递,根据误差来调整权值和阈值,达到期望误差^[21-22]。采用筛选出的3个影响因子月数据序列以及月用水量分别作为输入变量和输出变量对BP神经网络模型进行训练。将数据随机划分为训练集、验证集和测试集,比例分别设为70%、20%、10%。经过反复调参,得到隐含层神经元个数设为14时,陕西省月用水量整体拟合精度较好,因此,采用结构为3-14-1的BP神经网络。接着,采用Sigmoid函数作为隐含层传递函数,线性函数purelin作为输出层传递函数。

2.2.3 GA-BP神经网络模型

GA-BP神经网络包括神经网络结构确定、遗传算法优化和神经网络预测三个部分。在影响因子优化筛选的基础上,将2020年陕西省月用水量及其影响因子分别作为输出和输入变量,根据BP神经网络的网络结构,利用遗传算法全局搜索的特点对网络的初始权值和阈值进行寻优,有效克服了BP神经网络易陷入局部极值等缺点^[23-24]。模型的初始参数采用BP神经网络随机生成,种群为多组权值、阈值,个体为其中的一组权值和阈值。遗传算法直接以目标函数作为搜索信息,通过计算个体的适应度函数,即2017—2019年陕西省月用水量真实值和预测值的差的绝对值之和,保留种群中误差小的个体,并以此为依据确定进一步的搜索方向,使神经网络的初始权值向着误差逐代减小的方向搜索,最终

找到满足条件的最优个体,即优异的权值和阈值,用于表示输入变量和输出变量的映射关系^[25-26]。

在 GA-BP 神经网络的构建过程中,除遗传算法特有的参数外,其余相关参数均与 BP 神经网络保持一致。设定遗传算法的进化代数为 40,种群规模为 10,交叉概率和变异概率分别设为 0.7 和 0.2。最终得到种群在遗传到 26 代以后,适应度达到稳定。

3 结果与分析

3.1 不同模型月用水量预测结果比较

为探究 ARIMA 模型、BP 神经网络模型和 GA-BP 神经网络模型对陕西省月用水量预测的适用性,对这三种模型的预测结果进行了比较(图 1 和表 3)。由图 1 可知,陕西省月用水量年内分布不均,2—7 月呈现递增趋势,7 月达到顶峰,7—11 月呈现递减趋势,11 月进入低谷,具有明显的季节差异。由于农业用水在总用水量中占主导地位,陕西省主要农作物为小麦、玉米、水稻、棉花等,其种植期多集中在春季,且春夏季对灌溉需求较大,导致春夏季用水量增长;秋季气温下降,农作物逐渐成熟并收获,用水量也相应减少。月用水高峰期气温较高,导致居民日常用水激增,同时也会对工业、企业用水量产生影响。比较三个模型的预测结果,ARIMA 模型和 GA-BP 神经网络模型的平均相对误差均在 5% 以内,分别为 2.45% 和 1.97%,而传统 BP 神经网络模型的平均相对误差为 5.36%。由于月用水量数据监测序列较短,2017—2020 年的年内趋势相近,年际变化相对稳定,因此各模型都得到了较好的预测结果。GA-BP 神经网络模型运用多层显隐神经元计算,并且引入遗传算法改进 BP 神经网络,提高了其全局搜索能力和网络性能,因此 GA-BP 神经网络模型的预测结果优于 ARIMA 模型和传统 BP 神

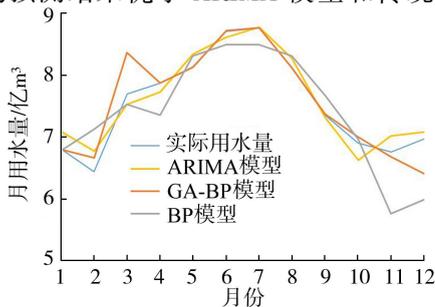


图 1 2020 年陕西省月用水量预测结果

表 3 2020 年陕西省月用水量预测精度对比

模型	平均相对误差 /%	与水资源公报年值对比误差 /%
ARIMA	2.45	2.30
GA-BP	1.97	2.11
BP	5.36	5.78

经网络模型。三种模型预测误差较大的月份主要集中在 2 月、3 月和 12 月,与 2017—2019 年月用水量数据相比,2020 年这几个月的实际用水量数据波动较大,经过分析,很可能是由于新冠疫情对社会经济的影响。此外,将月用水量预测值累加得到 2020 年总用水量,并与水资源公报年用水量进行对比,三种模型预测相对误差分别为 2.30%、2.11% 和 5.78%,均达到了较好的预测结果。

3.2 影响因子优选对 GA-BP 神经网络模型预测精度的提升作用

为验证影响因子优选的合理性,采用三种不同的方法来筛选影响因子,分别为 MIV 方法、皮尔逊相关系数(Pearson correlation coefficients, PCCs)方法、MIV 和 PCCs 联合方法。将三种方法得到的影响因子作为输入变量(表 4),通过 GA-BP 神经网络模型预测月用水量,得到的预测结果见图 2。可知,仅采用 MIV 或 PCCs 筛选出的影响因子作为输入变量,得到的预测结果误差较大,平均相对误差分别为 4.99% 和 4.61%,最大误差达到了 12.91% 和 9.04%,影响了模型的预测性能。这是因为,只采用 MIV 作为筛选标准,可能会引入与月用水量关系不紧密的影响因子,增加模型的复杂度并降低预测性能,难以得到全局优化解,导致预测精度降低;而只采用 PCCs 作为筛选标准,可能会忽略某些与月用水量关系密切的影响因子,影响预测结果的准确性。采用 MIV 和 PCCs 联合方法开展影响因子筛选,可以弥补单独使用一种方法的不足,提高影响因子的选取精度,从而使 GA-BP 神经网络模型获得更为精确的预测结果,这也验证了影响因子优化的重要性,说明准确地选择与月用水量关系密切的影响因子作为输入变量,能够提高模型的可靠性。

表 4 三种方法对影响因子的筛选结果

方法	筛选后影响因子
MIV	月平均气温、第二产业增加值、第三产业增加值、居民人均可支配收入和发电量
PCCs	月平均气温、月降水量
MIV 和 PCCs 联合	月平均气温、第二产业增加值和发电量

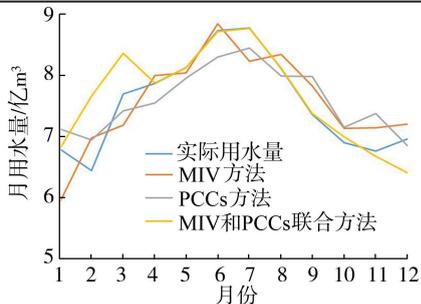


图 2 基于不同影响因子筛选方法的 GA-BP 神经网络模型的预测结果

4 结 论

a. ARIMA 模型、BP 神经网络模型和 GA-BP 神经网络模型在预测月用水量方面都具有较好的精度,三个模型预测值的平均相对误差为 2.45%、5.36%和 1.97%。

b. 相比于传统 BP 神经网络模型,引入 GA 优化算法能够提高模型的预测精度和运算效率。此外,通过采用 MIV 和 PCCs 联合方法对影响因子进行筛选,能够有效去除冗余属性,提高模型的预测性能。

c. 目前我国月尺度水资源监测处于初步阶段,可获取的数据序列相对较短。随着监测技术的不断进步和智慧化进程的持续发展,能够更深入地探索更精细时空尺度的用水量预测。

参考文献:

[1] 张陈俊,朱炯焯,陈洁,等. 基于 LMDI 的长江经济带用水量时空差异的驱动效应[J]. 水利经济,2024,42(3):14-20. (ZHANG Chenjun, ZHU Jiongye, CHEN Jie, et al. Driving effect of spatial-temporal difference in water consumption in the Yangtze River Economic Belt based on LMDI [J]. Journal of Economics of Water Resources,2024,42(3):14-20. (in Chinese))

[2] 许银山,吕孙云,梅亚东,等. 等维新息径向基神经网络模型在需水预测中的应用[J]. 水资源保护,2012,28(2):8-11. (XU Yinshan, LYU Sunyun, MEI Yadong, et al. Application of equi-dimensional information renewal radial basis function neural network model to urban water demand forecast[J]. Water Resources Protection,2012,28(2):8-11. (in Chinese))

[3] 范怡静,刘真,苑佳,等. 基于 LSTM-Neural Prophet 模型的城市需水预测方法研究[J]. 中国农村水利水电,2023(9):35-45. (FAN Yijing, LIU Zhen, YUAN Jia, et al. Research urban water demand forecasting method based on LSTM-Neural Prophet model [J]. China Rural Water and Hydropower,2023(9):35-45. (in Chinese))

[4] 栾清华,庞婷婷,王志友,等. 需水量预测技术方法文献分析及其应用综述[J]. 人民黄河,2022,44(12):62-66. (LUAN Qinghua, PANG Tingting, WANG Zhiyou, et al. Review and bibliometrics analysis of prediction technology and method of water demand [J]. Yellow River,2022,44(12):62-66. (in Chinese))

[5] 白鹏,龙秋波. 3 种用水量预测方法在京津冀地区的适用性比较[J]. 水资源保护,2021,37(2):102-107. (BAI Peng, LONG Qiubo. Applicability comparison of three water consumption prediction methods in Beijing-Tianjin-Hebei region [J]. Water Resources Protection,2021,37(2):102-107. (in Chinese))

[6] OYEBODE O, IGHRAVWE D E. Urban water demand forecasting: a comparative evaluation of conventional and

soft computing techniques [J]. Resources, 2019, 8(3): 156.

[7] VILLARIN M C, RODRIGUEZ-GALIANO V F. Machine learning for modeling water demand[J]. Journal of Water Resources Planning and Management, 2019, 145(5): 04019017.

[8] NIKNAM A, ZARE H K, HOSSEININASAB H, et al. A critical review of short-term water demand forecasting tools: What method should I use? [J]. Sustainability, 2022,14(9):541.

[9] 王浏琳,陈家栋,张方敏. 基于神经网络的南京市用水量预测[J]. 水电能源科学,2023,41(12):28-31. (WANG Liulin, CHEN Jiadong, ZHANG Fangmin. Prediction of Nanjing water consumption based on neural network[J]. Water Resources and Power,2023,41(12):28-31. (in Chinese))

[10] 周宇茗,陈恬玥,郭青,等. 中国内地分区年用水总量预测模型研究[J]. 水资源与水工程学报,2022,33(6):111-119. (ZHOU Yuming, CHEN Tianyue, GUO Qing, et al. Prediction models of regional annual total water consumption in mainland China [J]. Journal of Water Resources and Water Engineering,2022,33(6):111-119. (in Chinese))

[11] RISTOW D C M, HENNING E, KALBUSCH A, et al. Models for forecasting water demand using time series analysis: a case study in Southern Brazil [J]. Journal of Water, Sanitation and Hygiene for Development, 2021, 11(2):231-240.

[12] ZUBAIDI S L, ORTEGA-MARTORELL S, AL-BUGHARBEE H, et al. Urban water demand prediction for a city that suffers from climate change and population growth: Gauteng Province case study [J]. Water, 2020, 12(7):1885.

[13] 张灵,陈晓宏,刘丙军,等. 基于 AGA 的 SVM 需水预测模型研究[J]. 水文,2008,28(1):38-42. (ZHANG Ling, CHEN Xiaohong, LIU Bingjun, et al. SVM model of water demand prediction based on AGA [J]. Journal of China Hydrology,2008,28(1):38-42. (in Chinese))

[14] 许月萍,曾田力,周欣磊,等. 基于主要驱动因子筛选法和深度学习算法的浙江省动态需水量预测[J]. 水利水电科技进展,2024,44(2):47-53. (XU Yueping, ZENG Tianli, ZHOU Xinlei, et al. Forecast of dynamic water demand in Zhejiang Province based on main driving factor screening method and deep learning algorithm [J]. Advances in Science and Technology of Water Resources, 2024,44(2):47-53. (in Chinese))

[15] REICHSTEIN M, CAMPS-VALLS G, STEVENS B, et al. Deep learning and process understanding for data-driven Earth system science [J]. Nature, 2019, 566(7743): 195-204.

[16] MENG Pai, HUANG Juan, KONG Deguang. Prediction of incidence trend of influenza-like illness in Wuhan based

- on ARIMA model [J]. Computational and Mathematical Methods in Medicine, 2022, 2022: 6322350.
- [17] 马于航, 索梅芹. 基于 GA-BP 神经网络与正态区间估计的需水预测: 以邯郸市为例 [J]. 中国农村水利水电, 2022(3): 19-24. (MA Yuhang, SUO Meiqin. Research on water demand forecasting in Handan city based on GA-BP neural network and normal interval estimation [J]. China Rural Water and Hydropower, 2022 (3): 19-24. (in Chinese))
- [18] SINGH S, SUNDRAM B M, RAJENDRAN K, et al. Forecasting daily confirmed COVID-19 cases in Malaysia using ARIMA models [J]. The Journal of Infection in Developing Countries, 2020, 14(9): 971-976.
- [19] 苏志伟, 吴元梅, 张丽娟, 等. 基于 MEA-GA-BP 耦合模型的城市需水量预测 [J]. 水电能源科学, 2022, 40(11): 31-34. (SU Zhiwei, WU Yuanmei, ZHANG Lijuan, et al. Urban water demand prediction based on MEA-GA-BP coupling model [J]. Water Resources and Power, 2022, 40(11): 31-34. (in Chinese))
- [20] 罗光宇, 杨光明. 基于 MIV 分析的 GA-BP 神经网络闸门健康诊断 [J]. 水电能源科学, 2021, 39(11): 203-206. (LUO Guangyu, YANG Guangming. GA-BP neural network gate health diagnosis based on MIV analysis [J]. Water Resources and Power, 2021, 39(11): 203-206. (in Chinese))
- [21] 张宗堂, 肖天祥, 高文华, 等. 交通荷载下煤矸石路基填料累积变形 PSO-BP 神经网络预测模型 [J]. 水利水电科技进展, 2024, 44(2): 87-91. (ZHANG Zongtang, XIAO Tianxiang, GAO Wenhua, et al. PSO-BP neural network prediction model for cumulative deformation of coal gangue subgrade filler under traffic loading [J]. Advances in Science and Technology of Water Resources, 2024, 44(2): 87-91. (in Chinese))
- [22] 朱诚, 王昭敏, 隆锋, 等. 基于 ABC-BP 神经网络的地铁盾构地表沉降预测 [J]. 河海大学学报(自然科学版), 2023, 51(4): 72-80. (ZHU Cheng, WANG Zhaomin, LONG Feng, et al. Prediction of ground settlement of subway shield based on ABC-BP neural network [J]. Journal of Hohai University (Natural Sciences), 2023, 51(4): 72-80. (in Chinese))
- [23] 崔东文. 基于相空间重构原理的遗传神经网络模型在城市需水预测中的应用 [J]. 水利水电科技进展, 2014, 34(1): 85-89. (CUI Dongwen. Application of genetic neural network model to urban water demand prediction based on theory of phase space reconstruction [J]. Advances in Science and Technology of Water Resources, 2014, 34(1): 85-89. (in Chinese))
- [24] 肖杨, 彭杨, 王太伟. 基于遗传算法与神经网络的水库水沙联合优化调度模型 [J]. 水利水电科技进展, 2013, 33(2): 9-13. (XIAO Yang, PENG Yang, WANG Taiwei. Water-sediment coordinated optimized dispatch model of reservoir based on genetic algorithm and neural network [J]. Advances in Science and Technology of Water Resources, 2013, 33(2): 9-13. (in Chinese))
- [25] LIU Zhengjun, LIU Aixia, WANG Changyao, et al. Evolving neural network using real coded genetic algorithm (GA) for multispectral image classification [J]. Future Generation Computer Systems, 2004, 20(7): 1119-1129.
- [26] 谷艳昌, 吴云星, 黄海兵, 等. 基于遗传算法优化支持向量机的大坝安全性态预测模型 [J]. 河海大学学报(自然科学版), 2020, 48(5): 419-425. (GU Yanchang, WU Yunxing, HUANG Haibing, et al. Prediction model of dam safety behavior based on genetic algorithm optimized support vector machine [J]. Journal of Hohai University (Natural Sciences), 2020, 48(5): 419-425. (in Chinese))

(收稿日期: 2023-12-21 编辑: 俞云利)

(上接第 72 页)

- [21] BRUNNER G W. HEC-RAS river analysis system: user's manual [R]. Vicksburg: US Army Corps of Engineers, Institute for Water Resources, Hydrologic Engineering Center, 2001.
- [22] HAVNØ K, MADSEN M N, DØRGE J. MIKE 11: a generalized river modelling package [C]//SINGH V P. Computer Models of Watershed Hydrology. Colorado: Water Resources Publications, 1995: 733-782.
- [23] 周兴波, 陈祖煜, 陈淑婧, 等. 基于 MIKE 11 的堰塞湖溃决过程数值模拟 [J]. 安全与环境学报, 2014, 14(6): 23-27. (ZHOU Xingbo, CHEN Zuyu, CHEN Shujing, et al. Simulation of the barrier dam breaching process based on MIKE 11 [J]. Journal of Safety and Environment, 2014, 14(6): 23-27. (in Chinese))
- [24] 陈祖煜, 张强, 侯精明, 等. 金沙江“10·10”白格堰塞湖溃坝洪水反演分析 [J]. 人民长江, 2019, 50(5): 1-4. (CHEN Zuyu, ZHANG Qiang, HOU Jingming, et al. Back analysis on dam-breach flood of “10. 10” Baige barrier lake on Jinsha River [J]. Yangtze River, 2019, 50(5): 1-4. (in Chinese))
- [25] 李相南, 陈祖煜. 两种溃坝模型在唐家山堰塞湖溃决模拟中的对比 [J]. 水利水电科技进展, 2017, 37(2): 20-26. (LI Xiangnan, CHEN Zuyu. Comparison of two models for back analysis of dam breach of Tangjiashan barrier lake [J]. Advances in Science and Technology of Water Resources, 2017, 37(2): 20-26. (in Chinese))
- [26] WU Weiming. Simplified physically based model of earthen embankment breaching [J]. Journal of Hydraulic Engineering, 2013, 139(8): 837-851.
- [27] WU Weiming. Introduction to DL Breach: a simplified physically-based dam/levee breach model [R]. Potsdam: Clarkson University, 2016.

(收稿日期: 2023-11-19 编辑: 骆超)