

DOI:10.13476/j.cnki.nsbdqk.2022.0079

刘晓伟, 哈明虎, 雷晓辉, 等. 基于 GRA-NARX 神经网络的泵站站前水位预测模型[J]. 南水北调与水利科技(中英文), 2022, 20(4): 773-781. LIU X W, HA M H, LEI X H, et al. Prediction model of water level in front of pumping station based on GRA-NARX neural network[J]. South-to-North Water Transfers and Water Science & Technology, 2022, 20(4): 773-781. (in Chinese)

基于 GRA-NARX 神经网络的 泵站站前水位预测模型

刘晓伟^{1,2}, 哈明虎¹, 雷晓辉^{1,3}, 张召³

(1. 河北工程大学水利水电学院, 河北 邯郸 056038; 2. 河北省智慧水利重点实验室, 河北 邯郸 056038;
3. 中国水利水电科学研究院, 北京 100038)

摘要:针对多种水工建筑物相互作用和影响下的泵站水位预测难题, 提出基于 GRA-NARX(grey relation analysis-nonlinear autoregressive model with exogenous inputs)神经网络的泵站站前水位预测模型。该模型包括灰色关联分析(GRA)和 NARX 神经网络两部分, 利用 3 种训练算法和不同时间延迟分别对密云水库调蓄工程屯佃泵站站前水位进行 2 h 预测, 并与 NARX 模型和 GRA-BP(grey relation analysis-back propagation)模型的预测结果进行比较。研究表明, GRA-NARX-BR(grey relation analysis-nonlinear autoregressive model with exogenous inputs-bayesian regularization)模型用于水位预测能够比较全面地考虑影响因子, 预测精度高, 相关系数最高达 0.986 62, 均方根误差最小为 0.008 6 m, 预测效果比 NARX 模型和 GRA-BP 模型好, 且时间延迟越长, 均方根误差越小。模型也可在其他调水工程中推广使用。

关键词:灰色关联分析; NARX 神经网络; BP 神经网络; 水位预测; 密云水库调蓄工程

中图分类号: TV675 文献标志码: A 开放科学(资源服务)标志码(OSID):



进行长距离输水调度时, 常在渠道中设置泵站等水工建筑物, 以解除地形条件对输水限制的影响。泵站在运行过程中需保持水位平衡, 避免出现水位大幅上升或下降等问题。若水位随时间发生较为急剧的变化, 不仅可能造成泵站间弃水, 甚至可能导致供水破坏或者引起整个系统的水力振荡^[1]。因此, 对水位信息进行处理, 建立合适的泵站水位预测模型, 尤其是泵站站前水位预测模型, 对泵站调控、水量调度、建筑物安全等都具有重要意义。

泵站站前水位预测的方法有很多种, 包括基于物理机理的水位模拟和基于机器学习的水位预测等。基于物理机理的水位模拟^[2-3], 主要以圣维南方程为控制方程的水动力模型模拟一维渠道水流为

主, 需要研究区较为完整的资料, 因此这种方法的使用存在一定局限性。机器学习方法包括向量机 RVM(relevance vector machine)模型^[4]、灰色系统 GM(1, 1)(grey model)模型^[5]、多元线性回归模型^[6]、神经网络模型^[7-20]等, 其中向量机 RVM 模型、灰色系统 GM(1, 1)模型、多元线性回归模型等的优点是适用复杂的预测任务, 缺点是这些方法的预测精度有待提高。近年来, 随着人工智能技术的发展, 神经网络在泵站水位预测中取得了较好的效果, 其中应用较为广泛的是 BP 神经网络。不过, BP 神经网络虽然能够进行非线性拟合, 但不具备反馈记忆功能。NARX(nonlinear auto-regressive model with exogenous inputs)神经网络是 CHEN 等^[21]基

收稿日期: 2022-01-24 修回日期: 2022-06-24 网络出版时间: 2022-07-21

网络出版地址: <https://kns.cnki.net/kcms/detail/13.1430.TV.20220720.2032.006.html>

基金项目: 国家自然科学基金项目(51779268); 河北省自然科学基金面上项目(A2020402013)

作者简介: 刘晓伟(1983—), 女, 河北邯郸人, 讲师, 博士研究生, 主要从事复杂水资源系统预报与调度研究。E-mail: 470596294@qq.com

通信作者: 雷晓辉(1974—), 男, 陕西渭南人, 教授级高级工程师, 博士, 主要从事复杂水资源系统预报与调度研究。E-mail: lxh@iwhr.com

于线性回归模型提出的一种非线性有源网络结构,拥有输入延迟和反馈记忆功能,能够更好地对复杂的多输入、多输出系统进行逼近模拟。目前 NARX 神经网络主要用于渠道流量预测、地下水位预测、旱涝预测等,如:EZZELDIN 等^[22]利用 NARX 神经网络对灌溉渠道的分水流量进行了预测,预测结果优于 RBF、CFD、FFBP 模型;WUNSCH 等^[23]利用 NARX 神经网络对德国西南部 6 眼观测井的地下水位进行预测,预测结果好;WANG 等^[24]利用 NARX 神经网络对长江流域旱涝进行预测,最后成功预测数据缺口期间的洪水事件;范哲南等^[25]针对大坝变形时间序列的非线性及形变值累计特性,引入 NARX 神经网络进行分析并实现变形预测,且预测结果比 BP 神经网络好。然而,基于 NARX 神经网络的泵站站前水位预测模型相对较少。同时,应用 NARX 神经网络对时间序列预测时,使用的训练算法大多为 Levenberg-Marquardt (LM),而很少对其他算法进行分析,也很少有 NARX 模型在时间延迟方面的探索。此外,不管采用何种预测模型,第一步可考虑筛选影响因子,

这样可降低预测的复杂度并保证预测的精度。本文利用灰色关联分析(GRA)和 NARX 神经网络的各自优势,构建一种新的基于 GRA-NARX 神经网络的泵站站前水位预测模型,利用 BR、LM、SCG 等 3 种训练算法及不同时间延迟分别给出密云水库调蓄工程屯佃泵站站前水位的 2 h 预测结果,将模型预测结果与 NARX 模型和 GRA-BP 模型进行比较分析,并评估 3 种训练算法及不同时间延迟对预测精度的影响。

1 基于 NARX 神经网络的泵站站前水位预测模型

NARX 神经网络的全称是带有外部输入的非线性自回归神经网络。它是一种有效的时间序列预测技术,是动态神经网络中的一类。泵站站前水位预测的 NARX 神经网络拓扑结构见图 1,包括输入层、隐含层、输出层等。输入层向量为泵站当前时刻站前水位信息的影响因子,具体影响因子需经筛选后获得,输出层向量为泵站当前时刻站前水位信息。

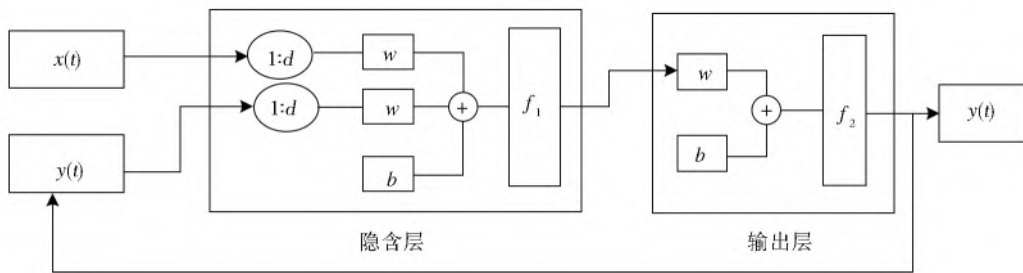


图 1 NARX 神经网络结构

Fig. 1 Structure of NARX neural network

基于 NARX 神经网络的泵站站前水位预测模型可表示为

$$y(t) = f(x(t-1), x(t-2), \dots, x(t-d),$$

$$y(t-1), y(t-2), \dots, y(t-d)) \quad (1)$$

式中: f 为非线性函数; $x(t)$ 表示泵站当前时刻站前水位信息的影响因子,为输入变量; $y(t)$ 表示泵站当前时刻站前水位信息,为输出变量; d 表示时间延迟。 $y(t)$ 可由 $x(t)$ 的前 d 个值和 $y(t)$ 的前 d 个值,通过非线性映射得到。输入层有 n 个神经元,网络输入为 x_1, x_2, \dots, x_n ,各层输出的计算公式为

$$H_j = f\left(\sum_{i=1}^n w_{ij}x_i - b_j\right) \quad (2)$$

式中: x_i 表示神经元的输入; w_{ij} 表示层与层之间的权重; b_j 表示该层的阈值; f (f 为 f_1, f_2) 表示激活函数。

2 基于 GRA-NARX 神经网络的泵站站前水位预测模型

2.1 水位监测数据清洗与插补

受设备故障、天气变化、人为干预等多种因素的影响,水情信息在采集过程中不可避免地会出现异常值。为保证预测的精度,首先需要对水情信息进行清洗。箱形图法作为一种检验样本中异常值的常用方法,与正态分布的拉依达准则、Z 分数法、格拉布斯法等不同,它适用范围广,可以应用到不服从正态分布的样本数据中^[26]。

箱形图中包含 5 个重要数据统计点,分别是被分析数据集的下四分位数 S_1 、中位数 S_2 、上四分位数 S_3 、下限值、上限值。上、下四分位数之间的距离被称为四分位距 R_{IQ} ,上、下限值可分别用 $S_3 +$

1.5R_{IQ}和 S₁-1.5R_{IQ}表示,见图 2。在图 2 中,分布在上、下限值以外的点即为箱形图识别出的异常值。检测出异常值后将其剔除,并对其和原有空值进行插补。




图 2 箱形图
Fig. 2 Boxplot

2.2 水位信息的主要影响因素筛选

泵站当前时刻的站前水位信息往往受上、下游一定区域内前一个或多个时刻的断面水位、泵站流量、泵站间流量差等多种因素的影响。这些因素对水位信息的影响程度不同,存在主次影响因子。为降低预测的复杂度并保证预测的精度,只考虑主要影响因子。GRA 是一种分析系统中各因素关联程度的量化方法,对样本数量多少无严格要求,数据也无须有典型的分布规律,具有广泛的适用性。具体步骤:

第一步 确定比较数列和参考数列。以被预测泵站当前时刻站前水位信息作为参考数列,泵站当前时刻站前水位信息的影响因子作为比较数列,比较数列有 m 个,评价指标有 n 个,参考数列为 $x_0 = \{x_0(k) | k = 1, 2, 3, \dots, n\}$, 比较数列为 $x_i = \{x_i(k) | k = 1, 2, 3, \dots, n\}, i = 1, 2, 3, \dots, m$

第二步 对参考数列和比较数列数据进行无量纲化处理。

第三步 计算参考数列与比较数列的灰色关联系数。灰色关联系数计算公式为

$$\xi_i(k) = \frac{\min_i(\min_k |x_0(k) - x_i(k)|) + \rho \max_i(\max_k |x_0(k) - x_i(k)|)}{|x_0(k) - x_i(k)| + \rho \max_i(\max_k |x_0(k) - x_i(k)|)} \quad (3)$$

式中: ρ 为分辨系数,取值区间为(0,1)。一般情况下,分辨系数 ρ 越大,分辨率越大;分辨系数 ρ 越小,分辨率越小。当 $\rho = 0.5463$ 时,分辨率最好,通常取 $\rho = 0.5$ 。

第四步 计算参考数列与比较数列的灰色关联度。

$$r_i = \frac{1}{n} \sum_{k=1}^n \xi_i(k) \quad i = 1, 2, 3, \dots, m \quad (4)$$

第五步 将灰色关联度按照大小进行排序, r_i 越接近 1 说明比较数列对参考数列的影响程度越高;当灰色关联度小于 0.6 时,认为两个数列无关;若灰色关联度大于 0.8 时,则认为两个数列的相关性很好。

2.3 GRA-NARX 神经网络预测模型确立

GRA-NARX 神经网络预测模型确立:首先对水位信息利用箱形图法进行清洗,采用均值填充法进行插补;然后利用 GRA 法确定当前时刻、当前位置处的水位信息的主要影响因子;最后将主要影响因子输入 NARX 神经网络,确定 NARX 神经网络的训练算法、时间延迟、输入层隐含层神经元个数等,进行网络训练。基于 GRA-NARX 神经网络的泵站站前水位预测模型流程见图 3。



图 3 基于灰色关联分析的 NARX 神经网络模型流程图
Fig. 3 Flow chart of NARX neural network model based on grey correlation analysis

2.4 预测结果评判标准

采用的评价标准为均方误差 MSE、均方根误差 RMSE 和相关系数 R。均方误差 MSE 和均方根误差 RMSE 反应的是预测值偏离实际值的程度,MSE 和 RMSE 越小,表明预测效果越好。相关系数 R 反应的是预测值与实际值之间的相关程度,R 越接近

1 相关程度越高。

$$E_{MS} = \frac{\sum_{i=1}^m (f_i - y_i)^2}{m} \quad (5)$$

$$E_{RMS} = \sqrt{\frac{\sum_{i=1}^m (f_i - y_i)^2}{m}} \quad (6)$$

$$R = \frac{\left| \sum_{i=1}^m (y_i - \bar{y}_i)(f_i - \bar{f}_i) \right|}{\sqrt{\left(\sum_{i=1}^m (y_i - \bar{y}_i)^2 \right) \left(\sum_{i=1}^m (f_i - \bar{f}_i)^2 \right)}} \quad (7)$$

式中: E_{MS} 为 MSE 值; E_{RMS} 为 RMSE 值; y_i 和 f_i 为水位实测值和水位预测值; \bar{y}_i 和 \bar{f}_i 为水位实测平均值和水位预测平均值; m 为数据列长度。

3 实例应用

3.1 区域概况与研究对象

密云水库调蓄工程于 2015 年 5 月投入运行, 用以提高北京市水资源战略储备和城市供水率。该工程从颐和园内的团城湖取水, 经 9 级泵站加压, 输送至密云水库 (图 4), 工程总长 103 km, 总扬程

132.85 m。前 6 级泵站分别建在屯佃闸、柳林倒虹吸、埝头倒虹吸、兴寿倒虹吸、李史山节制闸和西台上跌水节制闸旁, 串联京密引水渠输水至怀柔水库, 不设调蓄工程, 输水流量为 $20 \text{ m}^3/\text{s}$ 。后 3 级泵站从郭家坞泵站到溪翁庄泵站, 全长约 31 km, 包括 8 km 原京密引水渠道、22 km 直径 2.6 m 的单排 PCCP 管道和约 800 m 的钢管管道, 后 3 座加压泵站输水规模为 $10 \text{ m}^3/\text{s}$ 。

本文研究对象为整个复杂输水系统的第一级密云水库调蓄工程屯佃泵站, 该站位于海淀区京密引水渠屯佃节制闸北侧, 为渠道直接提升泵站, 与屯佃节制闸配合运用, 设计扬程 1.71 m; 距离上一个控制节点团城湖北闸 8.1 km, 沿程主要建筑物有安河扬水闸、农大分水闸、东干分水闸、北干分水闸、回民公墓扬水闸、五一分水闸、韩家川扬水闸、崔家窑分水闸和宏丰分水闸等; 距离下一个控制节点前柳林泵站 9.5 km, 沿程经冷泉桥上扬水闸、太舟坞分水闸、三星庄分水闸、温泉倒虹吸、北安河扬水闸、前柳林倒虹吸等。水流条件十分复杂, 水位预测难度较大。



图 4 密云水库调蓄工程示意图

Fig. 4 Schematic diagram of Miyun reservoir storage project

3.2 水位监测数据清洗与插补

选取屯佃泵站 2016 年 3 月 11 日至 2016 年 11 月 10 日的 2 868 个站前水位实测值为监测数据, 数据的时间间隔为 2 h。按照 2.2 描述的步骤, 利用箱形图法对数据进行清洗, 其中, 上四分位数为 49.2, 下四分位数为 49.07, 上限值为 49.395, 下限值为 48.875, 分布在上、下限值以外的点即为识别出的异

常值, 累计识别到 20 个异常值, 见表 1, 再对异常数据和原有的空值利用均值填充法进行插补。

3.3 水位信息的主要影响因子筛选、样本选择

考虑当前时刻的站前水位可能会受到上一个时刻的流量、上一时刻站前水位、上一时刻站后水位、上一时刻上一站闸前水位、上一时刻上一站闸后水位等因素的影响。以屯佃泵站当前时刻站前水位作

为参考数列,比较数列为上一时刻(两小时前)的已知值,共包括 5 个: r_1 表示屯佃泵站上一时刻流量; r_2 表示屯佃泵站上一时刻站前水位; r_3 表示屯佃泵站上一时刻站后水位; r_4 表示团城湖末端上一时刻闸前水位; r_5 表示团城湖末端上一时刻闸后水位。选取清洗好的 2 868 个监测数据作为分析序列,对数据进行无量纲化处理,消除量纲与单位的差异,按照 2.2 描述的步骤进行计算,结果见表 2。影响因子相关性排序从高到低依次为:屯佃泵站上一时刻站前水位;屯佃泵站上一时刻站后水位;屯佃泵站上一时刻流量;团城湖末端上一时刻闸后水位;团城湖末端上一时刻闸前水位。选择灰色关联度大于 0.8 的影响因子为主要影响因子。

表 1 监测数据中的异常值
Tab. 1 Outliers in monitoring data

时间	水位/m	时间	水位/m
7月20日 20:00:00	49.52	9月17日 14:00:00	48.85
7月20日 22:00:00	49.59	10月7日 22:00:00	48.87
7月21日 00:00:00	49.59	10月9日 04:00:00	48.86
7月21日 02:00:00	49.45	10月10日 12:00:00	48.86
9月17日 00:00:00	48.87	10月14日 04:00:00	48.87
9月17日 02:00:00	48.77	10月15日 08:00:00	48.87
9月17日 04:00:00	48.75	10月26日 02:00:00	48.86
9月17日 06:00:00	48.86	11月3日 04:00:00	48.87
9月17日 10:00:00	48.87	11月3日 06:00:00	48.86
9月17日 12:00:00	48.80	11月6日 16:00:00	48.87

表 2 各影响因子与当前时刻泵前水位的灰色关联度
Tab. 2 Grey correlation grade between each influence factor and the water level in front of the pumping station at the current time

序号	因子	关联度
1	r_1	0.651 2
2	r_2	0.945 6
3	r_3	0.866 9
4	r_4	0.640 1
5	r_5	0.641 7

因此,将屯佃泵站上一时刻站前水位、站后水位这两个主要影响因子作为神经网络模型的输入量,以屯佃泵站当前时刻站前水位作为 NARX 神经网络模型训练阶段的输出量,待预测量为屯佃泵站下一时刻(两小时后)站前水位。

3.4 预测模型构建

3.4.1 GRA-NARX 模型

将利用灰色关联分析筛选出的主要影响因子作为神经网络模型的输入量,屯佃泵站当前时刻站前

水位作为输出量,由 NARX 神经网络模型对数据序列进行训练和检验。由于目前没有成熟的理论为输入数据的划分比例、神经元个数、隐含层和输出层的转移函数、最大迭代次数等提供依据,故根据经验及试错法,确定输入数据划分比例为 70 : 15 : 15,它们依次是训练集、验证集和测试集,神经元个数为 20,隐含层和输出层的转移函数分别为“tansig”和“purelin”,最大迭代次数 1 000,学习率 10^{-3} ,其他参数设置为默认值。

3.4.2 GRA-BP 模型

为了比较不同的神经网络对相同输入的影响,GRA-BP 神经网络的输入因子与输出因子、输入数据划分比例、隐含层神经元个数、隐含层和输出层的转移函数等均与 GRA-NARX 神经网络一致,不同的是 GRA-NARX 神经网络的输出会反馈到下一个时刻的输入。

3.4.3 NARX 模型

NARX 模型的输入因子为屯佃泵站上一时刻流量、屯佃泵站上一时刻站前水位、屯佃泵站上一时刻站后水位、团城湖末端上一时刻闸前水位、团城湖末端上一时刻闸后水位,输出因子为屯佃泵站当前时刻站前水位,输入数据划分比例、隐含层神经元个数、隐含层和输出层的转移函数等均与 GRA-NARX 神经网络一致。

3.4.4 训练算法

采用 3 种训练算法对 GRA-NARX 模型、GRA-BP 模型和 NARX 模型进行研究。第一种训练算法是 LM,它收敛速度快,且收敛速度稳定,广泛应用于神经网络的时间序列预测;第二种训练算法是 BR(bayesian regularization),一般情况下,LM 算法速度快,而 BR 算法在复杂问题上效果更好;第三种训练算法是 SCG(scaled conjugate gradient),它是一种用于解决大型线性方程系统问题的迭代算法,收敛速度介于前两者之间。

3.5 结果分析

表 3 为 3 种训练算法的 GRA-NARX 模型和 NARX 模型不同时间延迟的预测结果。由表 3 可知:GRA-NARX-BR 模型(训练算法为 BR 的 GRA-NARX 神经网络)比 NARX 模型的预测结果好;不同的时间延迟下,均是 GRA-NARX-BR 模型下的相关系数最高,均方误差和均方根误差最小;在 GRA-NARX-BR 模型中,随时间延迟的增加,相关系数基本相当,均方误差和均方根误差越来越小,训练时长越来越长。

表 3 3 种训练算法的 GRA-NARX 模型和 NARX 模型不同时间延迟的预测结果

Tab. 3 Prediction of GRA-NARX model and NARX model of three training algorithms with different time delays

模型	时间延迟	训练算法 BR			训练算法 LM			训练算法 SCG		
		R	E_{MS}	E_{RMS}	R	E_{MS}	E_{RMS}	R	E_{MS}	E_{RMS}
NARX	2	0.984 22	$2.631 5 \times 10^{-4}$	0.016 22	0.983 12	$3.450 6 \times 10^{-4}$	0.018 58	0.970 45	$5.655 4 \times 10^{-4}$	0.023 78
	4	0.984 49	$2.978 5 \times 10^{-4}$	0.017 26	0.984 42	$2.962 4 \times 10^{-4}$	0.017 21	0.977 05	$4.344 9 \times 10^{-4}$	0.020 84
	6	0.985 92	$2.684 8 \times 10^{-4}$	0.016 39	0.983 03	$3.226 1 \times 10^{-4}$	0.017 96	0.974 77	$4.700 3 \times 10^{-4}$	0.021 68
	8	0.983 94	$2.488 2 \times 10^{-4}$	0.0157 7	0.984 15	$3.026 8 \times 10^{-4}$	0.017 40	0.976 37	$4.452 6 \times 10^{-4}$	0.021 10
	10	0.984 24	$2.435 8 \times 10^{-4}$	0.015 61	0.981 23	$3.583 4 \times 10^{-4}$	0.0189 3	0.971 61	$5.324 2 \times 10^{-4}$	0.023 07
	20	0.982 64	$2.132 9 \times 10^{-4}$	0.014 60	0.979 91	$3.981 2 \times 10^{-4}$	0.019 95	0.971 23	$5.335 8 \times 10^{-4}$	0.023 10
	30	0.982 66	$2.328 5 \times 10^{-4}$	0.015 26	0.983 41	$3.091 9 \times 10^{-4}$	0.017 58	0.968 61	$5.803 2 \times 10^{-4}$	0.024 09
GRA-NARX	2	0.985 68	$2.145 8 \times 10^{-4}$	0.014 65	0.980 1	$3.809 1 \times 10^{-4}$	0.019 52	0.968 83	$5.902 2 \times 10^{-4}$	0.024 29
	4	0.986 31	$1.517 2 \times 10^{-4}$	0.012 32	0.978 82	4.387×10^{-4}	0.020 95	0.975 87	4.016×10^{-4}	0.020 04
	6	0.986 62	$1.348 4 \times 10^{-4}$	0.011 61	0.978 67	$3.855 1 \times 10^{-4}$	0.019 63	0.969 13	3.922×10^{-4}	0.019 80
	8	0.984 32	$1.335 4 \times 10^{-4}$	0.011 56	0.984 3	$1.802 3 \times 10^{-4}$	0.013 42	0.976 09	$3.023 5 \times 10^{-4}$	0.017 39
	10	0.985 37	$1.311 2 \times 10^{-4}$	0.011 45	0.979 18	3.074×10^{-4}	0.017 53	0.951 98	7.932×10^{-4}	0.028 16
	20	0.984 16	$8.587 4 \times 10^{-5}$	0.009 21	0.974 68	$4.311 9 \times 10^{-4}$	0.020 77	0.974 31	4.617×10^{-4}	0.021 49
	30	0.983 23	$7.439 5 \times 10^{-5}$	0.008 62	0.978 73	$3.252 7 \times 10^{-4}$	0.018 04	0.977 57	3.693×10^{-4}	0.019 22

图 5 为 GRA-NARX 模型和 GRA-BP 模型在不同训练算法下实测值与预测值散点图。由于 GRA-NARX 模型的训练时长会随着时间延迟的增加而增加,设置时间延迟为 6,与 GRA-BP 模型对比。当训练算法为 BR 时, GRA-NARX 模型的 R 值为 0.986 62, GRA-BP 模型的 R 值为 0.956 03;

当训练算法为 LM 时, GRA-NARX 模型的 R 值为 0.978 67, GRA-BP 模型的 R 值为 0.970 02; 当训练算法为 SCG 时, GRA-NARX 模型的 R 值为 0.969 13, GRA-BP 模型的 R 值为 0.946 71。由此看, 3 种训练算法下的 GRA-NARX 模型, 相关系数均优于 GRA-BP 模型, GRA-NARX-BR 最优。

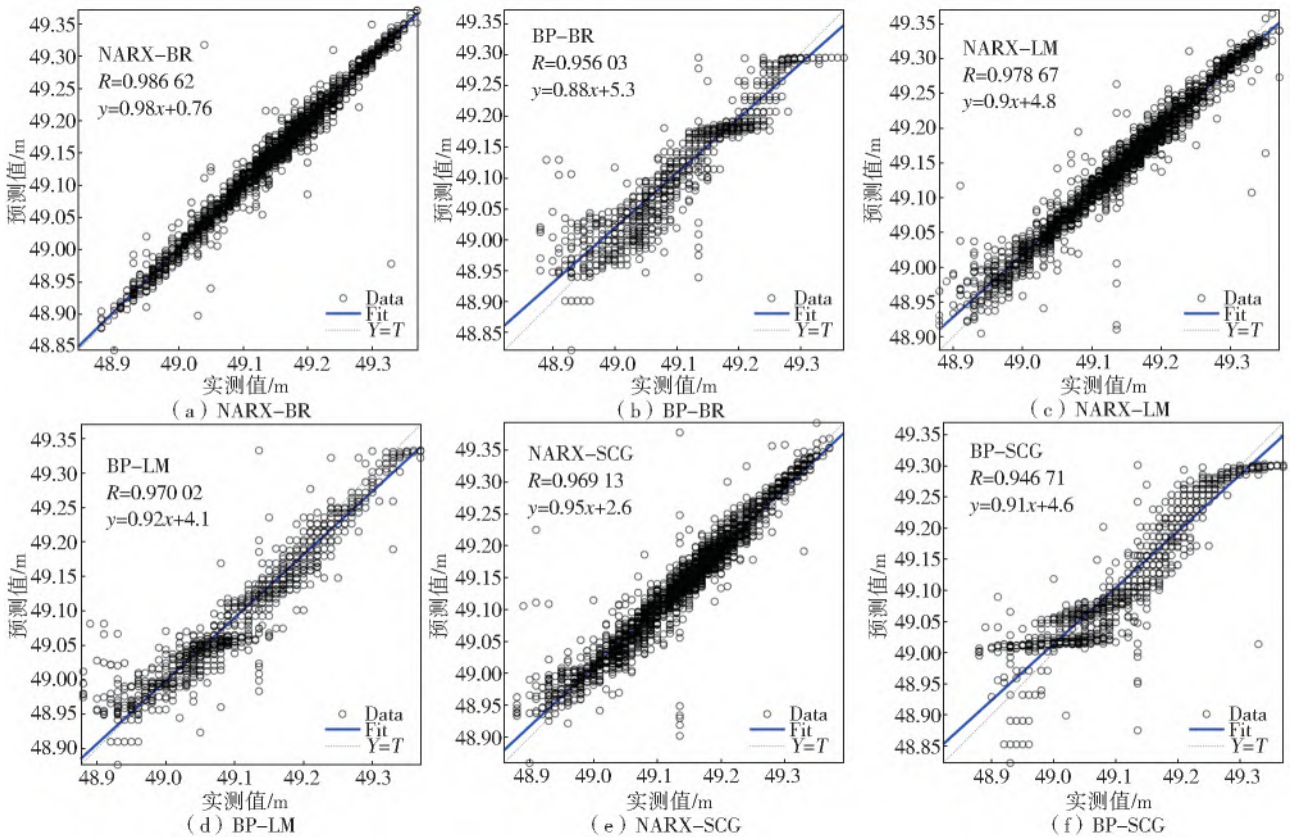


图 5 不同训练算法的 2 种神经网络实测值与预测值散点图

Fig. 5 Scatter plots of measured and predicted values for two neural networks with different training algorithms

表 4 为 GRA-NARX 模型和 GRA-BP 模型在不同训练算法下的均方误差和均方根误差, GRA-NARX 模型的时间延迟设置为 6。结果显示:当训练算法为 BR 时, GRA-NARX 模型的均方误差为 1.3484×10^{-4} , 均方根误差为 0.011 61, GRA-BP 模型的均方误差为 8.7416×10^{-4} , 均方根误差为 0.029 57;当训练算法为 LM 时, GRA-NARX 模型的均方误差为 3.8551×10^{-4} , 均方根误差为 0.019 63, GRA-BP 模型的均方误差为 9.5841×10^{-4} , 均方根误差为 0.030 96;当训练算法为 SCG 时, GRA-NARX 模型的均方误差为 3.9220×10^{-4} , 均方根误差为 0.019 80, GRA-BP 模型的均方误差为 9.9781×10^{-4} , 均方根误差为 0.031 59。以上分析说明, GRA-NARX 模型的均方误差和均方根误差比 GRA-BP 模型的均方误差和均方根误差都小, GRA-NARX-BR 模型的均方误差和均方根误差最小。

表 4 2 种模型不同训练算法的均方误差和均方根误差
Tab. 4 Mean square errors and root mean square errors for two models of different training algorithms

训练 算法	GRA-NARX		GRA-BP	
	E_{MS}	E_{RMS}	E_{MS}	E_{RMS}
BR	1.3484×10^{-4}	0.011 61	8.7416×10^{-4}	0.029 57
LM	3.8551×10^{-4}	0.019 63	9.5841×10^{-4}	0.030 96
SCG	3.9220×10^{-4}	0.019 80	9.9781×10^{-4}	0.031 59

4 结 论

本文利用灰色关联分析(GRA)和 NARX 神经网络的各自优势,构建了一种新的基于 GRA-NARX 神经网络的泵站站前水位预测模型,利用 BR、LM、SCG 等 3 种训练算法及不同时间延迟分别给出了密云水库调蓄工程屯佃泵站站前水位的 2 h 预测结果,将模型预测结果与 NARX 模型和 GRA-BP 模型进行比较,并评估了 3 种训练算法及不同时间延迟对预测精度的影响,得到如下结论:

基于 GRA-NARX 神经网络的泵站站前水位预测模型可降低预测的复杂度并保证预测的精度,具有广泛的适用性,能够很好地对复杂的多输入、多输出系统进行逼近模拟,模型适用调水工程的数据情况,相关系数最高达 0.986 62,均方根误差最小为 0.008 6 m。

3 种训练算法下的 GRA-NARX 模型中,训练算法为 BR 的 GRA-NARX 神经网络(GRA-NARX-BR 模型)能够高精度预测屯佃泵站站前水位,表现最好,相关系数最高,均方误差最小,预测精度高于 NARX 模型和 GRA-BP 模型,所提模型可

作为其他泵站站前水位预测替代模型。

在 GRA-NARX-BR 模型中,随着时间延迟的增加,相关系数基本相当,均方误差越来越小,训练时长越来越长。

由于影响密云水库调蓄工程梯级泵站水位变化的因素比较多,今后将进一步考虑模型输入的复杂性和多样性对预测结果的影响。此外,如何更科学的选取模型参数也是下一步需要研究的工作。

参考文献(References):

- [1] 吴辉明. 梯级泵站调水工程水力过渡过程分析及优化调度研究[D]. 北京:北京工业大学,2016. (WU H M. Research on hydraulic transient process analysis and scheduling optimization of multistage pumping stations in water transfer projects[D]. Beijing: Beijing University of Technology,2016. (in Chinese))
- [2] PRAMANIK N, PANDA R K, SEN D. One dimensional hydrodynamic modeling of river flow using DEM extracted river cross-sections[J]. Water Resources Management, 2010, 24(5): 835-852.
- [3] 郑和震, 马雄威, 雷晓辉, 等. 南水北调中线工程渠道糙率计算方法研究[J]. 南水北调与水利科技, 2018, 16(1): 158-163. (ZHENG H Z, MA X W, LEI X H, et al. Research on computing method for channel roughness of the Middle Route of South-to-North Water Transfer Project[J]. South-to-North Water Transfers and Water Science & Technology, 2018, 16(1): 158-163. (in Chinese)) DOI: 10. 13476/j. cnki. nsbdaq. 20180024.
- [4] 张研, 廖逸夫, 王鹏鹏, 等. 基于相关向量机的调水工程调蓄水位预测模型[J]. 南水北调与水利科技(中英文), 2021, 19(4): 814-821. (ZHANG Y, LIAO Y F, WANG P P, et al. Relevance vector machine model for predicting water level regulation in water transfer project[J]. South-to-North Water Transfers and Water Science & Technology, 2021, 19(4): 814-821. (in Chinese)) DOI: 10. 13476/j. cnki. nsbdaq. 2021. 0085.
- [5] GUO J L, TU L P, QIAO Z R. Forecasting the air quality in 18 cities of Henan Province by the compound accumulative gray model[J]. Journal of Cleaner Production, 2021, 310: 127582. DOI: 10. 1016/j. jclepro. 2021. 127582.
- [6] SAHOO S, JHA M. Groundwater-level prediction using multiple linear regression and artificial neural network techniques: A comparative assessment [J]. Hydrogeology Journal, 2013(21): 1865-1881. DOI 10. 1007/s10040-013-1029-5.
- [7] 刘青松, 严华, 卢文龙. 基于 AR-RNN 的多变量水位预

- 测模型研究[J]. 人民长江, 2020, 51(10): 94-99. (LIU Q S, YAN H, LU W L. Multivariable water level prediction based on AR-RNN model[J]. Yangtze River, 2020, 51(10): 94-99. (in Chinese)) DOI: 10. 16232/j. cnki. 1001-4179. 2020. 10. 016.
- [8] 唐鸣, 雷晓辉, 龙岩, 等. 基于长短时记忆网络(LSTM)的南水北调中线水位预测[J]. 中国农村水利水电, 2020(10): 189-193. (TANG M, LEI X H, LONG Y, et al. Water level forecasting in middle route of the south-to-north water transfer project based on Long Short-Term Memory (LSTM)[J]. China Rural Water and Hydropower, 2020(10): 189-193. (in Chinese))
- [9] RIHAM E A, AHMAD H B. Application of NARX neural network model for discharge prediction through lateral orifices [J]. Alexandria Engineering Journal, 2018, 57: 2991-2998. DOI: 10. 1016/j. aej. 2018. 04. 001.
- [10] ALSUMAIEI A A. A nonlinear autoregressive modeling approach for forecasting groundwater level fluctuation in urban aquifers [J]. Water, 2020, 12 (3): 12030820. DOI: 10. 3390/w12030820.
- [11] 高学平, 闫晨丹, 张岩, 等. 基于 BP 神经网络的调水工程调蓄水位预测模型[J]. 南水北调与水利科技, 2018, 16(1): 8-13. (GAO X P, YAN C D, ZHANG Y, et al. Prediction model for water level regulation in water transfer project based on BP neural network [J]. South-to-North Water Transfers and Water Science & Technology, 2018, 16(1): 8-13. (in Chinese)) DOI: 10. 13476/j. cnki. nsbdqk. 20180002.
- [12] TU Z J, GAO X G, XU J, et al. A novel method for regional short-term forecasting of water level[J]. Water, 2021, 13(6): 820. DOI: 10. 3390/w13060820.
- [13] 赵力学. 基于混合 BP 神经网络的河流水位流量预测方法研究[D]. 武汉: 武汉理工大学, 2019. (ZHAO L X. Research on river water level and flow forecasting method based on hybrid BP neural network[D]. Wuhan: Wuhan University of Technology, 2019. (in Chinese)) DOI: 10. 27381/d. cnki. gwlg. 2019. 000622.
- [14] REN T, LIU X F, NIU J W, et al. Real-time water level prediction of cascaded channels based on multi-layer perception and recurrent neural network [J]. Journal of Hydrology, 2020, 585: 124783. DOI: 10. 1016/j. jhydrol. 2020. 124783.
- [15] 臧冬伟, 陆宝宏, 朱从飞, 等. 基于灰色关联分析的 GA-BP 网络需水预测模型研究[J]. 水电能源科学, 2015(7): 45-48. (ZANG D W, LU B H, ZHU C F, et al. Study of GA-BP neural network for water requirement prediction based on gray correlation analysis[J]. Water Resources and Power, 2015(7): 45-48. (in Chinese))
- [16] XIONG B, LI R P, REN D, et al. Prediction of flooding in the downstream of the Three Gorges Reservoir based on a back propagation neural network optimized using the AdaBoost algorithm[J]. Natural Hazards, 2021, 107(2): 1559-1575. DOI: 10. 1007/S11069-021-04646-4.
- [17] TIAN Y, XU Y P, YANG Z, et al. Integration of a parsimonious hydrological model with recurrent neural networks for improved streamflow forecasting[J]. Water, 2018, 10 (11): 1655. DOI: 10. 3390/w10111655.
- [18] ZHANG J F, ZHU Y, ZHANG X P, et al. Developing a Long Short-Term Memory(LSTM) based model for predicting water table depth in agricultural areas[J]. Journal of Hydrology, 2018, 561: 918-929. DOI: 10. 1016/j. jhydrol. 2018. 04. 065.
- [19] BAEK S S, PYO J C, CHUN J A. Prediction of water level and water quality using a CNN-LSTM combined deep learning approach [J]. Water, 2020, 12 (12): 3399. DOI: 10. 3390/W12123399.
- [20] 吴美玲, 杨侃, 张铖铖. 基于 KG-BP 神经网络在秦淮河洪水水位预测中的应用[J]. 水电能源科学, 2019, 37(2): 74-77, 81. (WU M L, YANG K, ZHANG C C. Application of KG-BP neural network in flood forecasting of Qinhuai River [J]. Water Resources and Power, 2019, 37 (2): 74-77, 81. (in Chinese)) DOI: CNKI: SUN: SDNY. 0. 2019-02-019.
- [21] CHEN S, BILLINGS S A. Non-linear system identification using neural networks [J]. International Journal of Control, 1990, 51(6): 1191-1214.
- [22] EZZELDIN R, HATATA L. Application of NARX neural network model for discharge prediction through lateral orifices [J]. Alexandria Engineering Journal, 2018, 57: 2991-2998. DOI: 10. 1016/j. aej. 2018. 04. 001.
- [23] WUNSCH A, LIESCH T, BRODA S. Forecasting groundwater levels using nonlinear autoregressive networks with exogenous input (NARX) [J]. Journal of Hydrology, 2018, 567: 743-758. DOI: 10. 1016/j. jhydrol. 2018. 01. 045.
- [24] WANG J L, CHEN Y. Using NARX neural network to forecast droughts and floods over Yangtze River basin[J]. Natural Hazards, 2021, 105: 1-22. DOI: 10. 1007/S11069-021-04944-X.
- [25] 范哲南, 刘小生. NARX 神经网络在大坝变形预测中的应用[J]. 人民黄河, 2022, 44(2): 125-128. (FAN Z N, LIU X S. Application of NARX neural network in dam deformation prediction[J]. Yellow River, 2022,

44(2):125-128. (in Chinese)) DOI: 10. 3969/j. issn. 1000-1379. 2022. 02. 025.

[26] 赵超. 降雨异常值探测的改造箱形图法[J]. 中国农村

水利水电, 2012(9): 60-62. (ZHAO C. An adjusted boxplot for rainfall observations[J]. China Rural Water and Hydropower, 2012(9): 60-62. (in Chinese))

Prediction model of water level in front of pumping station based on GRA-NARX neural network

LIU Xiaowei^{1,2}, HA Minghu¹, LEI Xiaohui^{1,3}, ZHANG Zhao³

(1. School of of Water Conservancy and Hydroelectric Power, Hebei University of Engineering, Handan 056038, China;

2. Hebei Key Laboratory of Intelligent Water Conservancy, Handan 056038, China;

3. China Institute of Water Resources and Hydropower Research, Beijing 100038, China)

Abstract: The uneven distribution of water resources is a long-term and trend problem faced by many countries. The water transfer project is the main way to solve this problem. When long-distance water conveyance dispatching is carried out, hydraulic structures such as pumping stations are often set in the channels to remove the influence of topographic conditions on water conveyance restrictions. During operation, it is required to keep the water level balance among pumping stations as much as possible to avoid problems caused by sharp rises or falls in water levels. If the water level changes sharply with time, it may not only cause water abandonment among pumping stations, but also cause water supply damage or hydraulic oscillation of the whole system. Therefore, processing the water level information and establishing an appropriate water level prediction model of the pumping station, especially the water level prediction model in front of the pumping station, are of great significance to the management of the pumping station, water transfer, building safety and so on. However, up to now, it is still difficult to accurately predict the water level of the pumping station due to the interaction of various hydraulic structures.

A lot of studies have reported the research progress of water level prediction based on physical mechanism and machine learning. The water level simulation based on physical mechanism mainly uses the hydrodynamic model with Saint Venant equation as the control equation to simulate one-dimensional channel flow. It requires complete information in the study area, but usually some data is missing. Therefore, this method has certain limitations. Machine learning methods include vector machine RVM model, grey system GM(1,1) model, multiple linear regression model, neural network model, etc. The advantages of vector machine RVM model, grey system GM(1,1) model and multiple linear regression model are suitable for complex prediction tasks, but the disadvantages are that the prediction accuracy of these methods need to be improved. In recent years, with the development of artificial intelligence, neural network has got plentiful results in water level prediction. NARX neural network is a nonlinear dynamic network structure. Based on linear regression model, it has the functions of input delay and feedback memories, and can better approximate and simulate complex multi input and multi output systems.

In order to further improve the accuracy of water level prediction, a water level prediction model based on GRA-NARX neural network was proposed, which included grey relational analysis (GRA) and NARX neural network. At present, when using NARX neural network to predict time series, Levenberg Marquardt (LM) algorithms is the most commonly used training algorithm, while the other two algorithms are rarely evaluated. Taking Tundian pumping station of Miyun reservoir storage project as a research case, firstly, the water level information was cleaned by boxplot method, and then interpolated by mean filling method; secondly, the main factors were screened out by grey correlation analysis; thirdly, the water level prediction model of NARX neural network based on grey correlation analysis was constructed; finally, an analysis was performed in order to assess the impact on the water level prediction of different training algorithms and time delays, and compared with GRA-BP neural network.

The results show that the Bayesian Regularization (BR) algorithm leads to prediction model with better forecasting accuracy of the highest correlation coefficient and the smallest mean square error among the three different training algorithms. In GRA-NARX-BR model, with the increase of time delay, the correlation coefficient is basically the same, the mean square error is smaller and smaller, and the training time is longer and longer. Compared with the prediction results of GRA-BP model, it is found that among the three training algorithms, GRA-NARX model can comprehensively consider the influencing factors in water level prediction, has better network prediction accuracy, and GRA-NARX-BR model has the highest prediction accuracy, which reflects the superiority of GRA-NARX model structure and strong network generalization ability, and can be used as an effective water level prediction method.

Key words: grey correlation analysis; NARX neural network; BP neural network; water level prediction; Miyun reservoir storage project