

水位预测的机器学习方法

张树波 

广州航海学院计算机系, 广东 广州

收稿日期: 2024年12月27日; 录用日期: 2025年3月4日; 发布日期: 2025年3月12日

摘要

水是所有生命的物质基础, 与人类的生活、生产息息相关, 水资源的开发和利用对生活生产、生态环境和社会经济发展具有重要的影响。研究水位动态变化规律以及提前预测水位, 对于水资源的开发利用、湿地保护、防洪减灾、船舶配载和安全通航等具有重要的现实意义。水位的高低受到天气、水文等各种复杂因素的影响, 水位预测是水文、气象、航道和海事等部门关注的难题和研究热点。本文对近年来机器学习方法在水位预测方面的研究进展和所取得的成果进行分析和评述, 分析了现有方法存在的问题和面临的挑战, 指出水位预测未来的主要研究方向。

关键词

水位预测, 机器学习, 时间序列, 特征提取

Machine Learning Approaches for Water Level Prediction

Shubo Zhang 

Department of Computer Science, Guangzhou Maritime University, Guangzhou Guangdong

Received: Dec. 27th, 2024; accepted: Mar. 4th, 2025; published: Mar. 12th, 2025

Abstract

Water is the basis for all life and is closely related to human life and production. The development and utilization of water resources have a significant impact on life, production, ecological environment, and social and economic development. Investigating the dynamic patterns of water level changes and forecasting water levels ahead of time are of great practical importance. They play a crucial role in multiple aspects, such as the exploitation and utilization of water resources, the conservation of wetlands, the prevention of floods and reduction of disasters, the loading arrangements of ships, and the guarantee of safe navigation. The water level is affected by various complex factors

文章引用: 张树波. 水位预测的机器学习方法[J]. 人工智能与机器人研究, 2025, 14(2): 290-303.

DOI: 10.12677/airr.2025.142029

such as weather and hydrology. The prediction of water level is a difficult thing concerned by departments such as hydrology, meteorology, etc. hence it has become the research focuses in the past years. In this paper, various machine learning algorithms used for predicting water level are reviewed and commented, and the challenge that researchers in this field faced is then pointed out, in the end, the perspectives in this realm are also proposed.

Keywords

Water Level Prediction, Machine Learning, Time Series, Feature Extraction

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

水是生命之源，是所有生物赖以生存的重要物质基础，它与居民生活、农田灌溉、工业生产、水路运输等息息相关，水资源的开发和利用对生活生产、生态环境和社会经济发展具有重要的影响[1]。研究水位动态变化规律以及提前预测水位，对于水资源的开发利用、湿地保护、防洪减灾、船舶配载和安全通航等具有重要的现实意义[2]。由于河流、湖泊、水库、湿地和地下水的水位高低的影响因素不尽相同，水位变化与各因素之间呈复杂的非线性关系[3]，预测难度大，水位预测一直以来是水文、气象、航道和海事等部门关注的难题和研究热点。

早期水位预测主要使用模型驱动的方法[4]，这类方法主要基于流体力学理论、数理统计方法或者物理实验，分析水文特征并建立相应的物理模型，然后根据模型来计算和预测水位的高低。1856年法国水利工程师达西通过实验提出了达西定律[5]，刻画了水在空隙介质中的运动规律，为早期定量计算和研究地下水位奠定了理论基础。1935年泰斯提出的地下水向井孔不稳定流动公式为近代研究地下水位提供了新的方向[6]。1979年Cunningham和Sinclair[7]建立的耦合模型在美国内华达州北部Truckee河流的水位预测中取得较好的效果。李永凯等人[8]结合水力学模型和水文模型对沮漳河的水文站洪峰水位进行预测。李加龙[9]运用一维水动力模型DYRESM对抚仙湖1959~2050年水位进行模拟，预测了抚仙湖2021~2050年水位变化趋势。理论上模型驱动的水位预测方法可以实现水位的精确计算，而且预测结果具有良好的物理解释。由于水动力系统很复杂，影响水位的因素较多，需要考虑降雨、地形、水工建筑物等因素，导致物理模型十分复杂，计算复杂度高且比较耗时，对水位高效预测仍存挑战[10]；另一方面，基于模型的方法需要对研究人员的专业知识要求比较高，模型中涉及大量的水文地质参数，而在很多时候能够得到的关于模型参数的数据是有限的，这就限制了基于模型驱动的水位预测方法的有效应用。

对于水位高度预测的应用而言，我们往往关心的是预测的准确度，而不关心其物理上的机制[11]。因此，如何根据已有的历史水位数据预测未来的水位高度，逐渐成为人们关注的焦点。随着遥感遥测技术和电子信息技术的发展，越来越多的水位检测设施和设备被安装来实时测量水位高度，这些水位数据的积累为基于数据驱动的水位预测方法研究提供了重要的基础数据。而机器学习方法和技术的发展，为从大量水位历史数据中发现水位变化规律，预测未来水位高度提供了良好的技术手段。基于机器学习的水位预测方法不考虑水位变化的物理规律，而是基于水位和相关影响因素的历史数据，预测未来一段时间的水位，它本质上是求解时间序列预测的问题。这类方法需要解决以下三个方面的问题：(1) 时间序列的特征提取方法；(2) 时间序列的预测方法；(3) 时间序列预测方法的有效性评价。本文围绕这几个方面进

行综述,总结基于机器学习方法在水位预测方面取得的成果,探索该领域面临的问题和今后的研究方向。第2节讨论如何从历史数据中提取能够刻画水位变化规律的特征;第3节讨论水位预测中的机器学习方法;第4节总结水位预测的有效性评价方法;第5节指出机器学习方法未来在水位预测方面的研究方向。

2. 水位数据的特征选择与提取方法

在基于机器学习方法的水位预测研究中,一项重要的工作是从历史数据中筛选出对水位预测有帮助的信息。一般来说我们得到的数据除了历史水位高度数据之外,通常还可以获取到河道流量、降雨量、辐射、气温、饱和差、蒸发量、人工开采、灌溉、沟道排泄、地下水侧向交换等各种原始数据,如何根据已有的历史数据构造水位预测模型的输入输出数据,使得机器学习模型能够根据输入数据对未来水位进行准确的预测是水位预测研究核心任务。这项工作通常需要做两件事,一是根据原始的历史水位数据构造出模型的输入和输出数据,二是从其它历史资料中筛选出那些与水位有关的特征,将这些特征数据与历史水位数据一起作为模型的输入。为了完成这项工作,需要用到特征选择和特征提取这两种机器学习技术。

特征选择和提取是机器学习研究的重要内容,它们的目标是在基础数据集上发现能够有效刻画研究对象的特征,提高机器学习的效果,减少数据集中的特征数目,降低计算的复杂度。

2.1. 水位数据的特征选择方法

特征选择是指从原始的数据中找出与研究问题相关的特征子集,它是机器学习中一个非常活跃的研究领域,在基因筛选、图像识别、文本分类和客户关系管理等方面具有广泛的应用。特征选择的策略有三类:(1) Filter 特征选择方法[12]。这种方法首先按照某个给定的度量标准计算每个特征重要性的得分值,然后对它们进行排序,再选择那些重要性得分高的特征作为目标特征,常用的度量有相关系数、方差、Fisher Score、信息熵、 χ^2 值、 t 值和 Wilcoxon 值等,这类方法简单,计算的复杂度也较低,但是它们没有考虑特征之间的相关性,被选择的特征之间可能存在一定的相关性和冗余性,这将增加计算的负担,因此有必要进一步将这些冗余的特征排除掉。(2) Wrapper 特征选择方法[13]。这种方法的一般做法是从特征空间搜索所有特征子集,对每个子集分别构造模型,以模型的预测效果作为每个子集的得分,将得分最高的特征子集作为目标子集。Wrapper 方法将特征子集的选择与相应模型的性能结合起来,因此一旦确定了特征子集,就不需要进一步设计预测模型,而且也将特征之间的相关性考虑进特征选择的过程,但是其计算的复杂度非常高,算法的复杂程度明显高于 filter 方法[14],对维数较高的特征选择问题是不可取的。(3) Embedded 特征选择方法[15]。这种方法将特征选择问题嵌入到模型的设计中,通过模型决定各个特征的重要性系数,该方法计算的效率比较高。

我们知道水位的变化不是孤立的,而是受像历史的降水量、气温、辐射等因素影响的复杂过程,如果能够找出那些对水位变化有影响的因素,将有助于建立合适的模型来刻画水位的变化规律,实现对水位的准确、可靠预测。目前用于筛选水位预测相关特征的方法主要有两种,一种是基于相关系数的方法,另一种是基于互信息的方法。基于相关系数的方法可以有效地找出与水位变化具有线性关系的特征,Das [16]通过计算变量之间的相关系数,发现前3年、前1年、前1个月、前2天、前1天的水位与要预测那天的水位相关性较高;马森标等[3]通过计算皮尔逊相关系数筛选出降雨量、泄洪量和历史水位这三个与水库水位变化相关性较强的特征,再根据这些特征构造时效分量对水库的水位进行预测。基于互信息的特征选择方法是根据随机变量之间相互依赖程度来筛选特征的,其定义为

$MI(Y;X) = \sum_{x \in X} \sum_{y \in Y} p(x,y) \log p(x,y) [p(x)p(y)]$, 互信息的值越大表明变量之间的关联程度越高[17],采用这种方法可以有效的选出与水位存在非线性关系的特征。Choi [18]在研究湿地水位预测问题时,

利用互信息方法发现上游水位比降水量和风速对水位的影响程度更高,一天前的数据比2、3天前的数据与水位的关联度更高。王迎飞等人[19]研究发现枝城、沙市、宜昌、监利和螺山5个水文站与武汉水文站的互信息值均大于0.49,他们利用这5个水文站的历史水位数据作为模型输入对武汉站的水位进行预测。

2.2. 水位数据的特征提取方法

机器学习中的特征提取是通过一个特征变换将数据从原始特征空间映射到新的特征空间中,用新特征空间中的数据来刻画研究对象,这类变换包括PCA变换、LDA变换、SVD变换、Gabor变换、Fourier变换和小波变换等。在水位预测研究中,研究人员用于提取水位特征信息的方法主要有三类:(1)调和分析方法;(2)小波分析方法;(3)经验模态分解方法。

(1) 调和分析方法

调和分析方法也称Fourier分析方法,它是一种传统的信号分析技术,采用一系列谐波信号来逼近原始信号,其数学模型如下[20]:

$$h(t_i) = h_0 + \sum_{j=1}^n C_j \cos(\omega_j t_i) + D_j \sin(\omega_j t_i)$$

其中 $h(t_i)$ 就是在时刻 t_i 的水位, $i=1,2,\dots,N$, h_0 是平均水位, n 是谐波的个数, C_j 是第 j 个余弦波的系数, D_j 是第 j 个正弦波的系数, ω_j 是第 j 个谐波的频率,采用矩阵形式表示为 $h = Ax$,其中 $h = [h(t_1), h(t_2), \dots, h(t_N)]^T$, A 是由 n 个谐波信号的正弦分量和余弦分量构成的矩阵,

$x = [h_0, C_1, D_1, \dots, C_n, D_n]^T$ 是未知的谐波系数,采用最小二乘法就可以求出模型的系数 $\hat{x} = (A^T W A)^{-1} A^T W h$ 。调和分析在水位预测方面的应用主要是通过天文潮和常数回报潮位,由此产生潮汐表来实现海水水位的预测[21],它能够准确地预测天文潮,但是对于那些由风和气压导致的残差水位却无法预测,对此Li[22]和Tu[23]先用调和分析预测天文潮,然后用神经网络来预测残差水位,从而提高河口和沿海水域水位预测的准确度。调和分析在长期的潮汐预测方面具有良好的效果,但是对于非潮汐的水位预测往往不能取得好的结果[24]。

(2) 小波分析方法

水位信号是一种典型的非平稳信号,信号中的低频部分代表周期性和背景信息,而高频部分代表细节和噪声。小波变换具有多尺度分析能力,利用小波变换可以将水位序列中的高频部分与低频部分分割开来,进而研究水位变化的规律,因此研究人员经常利用小波的多分辨率特性对历史水位数据进行分析,提取不同尺度的信息,用于预测水位的高度。Malekzadeh[25]对Haar、Symlets、Dmeyer、Daubechies和Coiflets五种母小波进行测试,发现Dmeyer小波在地下水位预测方面效果最好。Wang[24]将Daubechies小波用于海水水位序列的分解,进而实现对海水水位的预测。Adamowski等人[26]用小波神经网络对地下水位进行预测,他们将神经网络中的激活函数替换为小波基函数,取得比普通神经网络更好的效果。倪汉杰等人[27]设计了一种将长短时记忆神经网络和小波分析耦合的神经网络模型,发现这种模型比其它的神经网络具有更好的预测效果。刘立燕[28]根据序列数据中前后天水位之间具有一定相关性的特点,将多个前期时间水位的小波分解系数也作为模型的输入,提高了模型的预测能力。Mohammed[20]等人认为调和分析有利于长期水位预测,而小波分析有利于短期水位预测,他们将调和分析和小波分析结合起来,提高海水水位预测的准确性。

(3) 经验模态分解方法

调和分析和小波分析方法需要预先设定基函数,它们都不具备尺度搜索的自适性,并且可能会产生虚假的波动尺度信息。为了解决这样的问题,1998年Huang[29]提出了一种能够根据数据自身的尺度特征对信号进行分解的方法,即经验模态分解(Empirical Mode Decomposition, EMD),它的做法是先把一个

复杂的信号分解成有限个本征模函数(Intrinsic Mode Function, IMF), 每个 IMF 分量包含了原始信号中不同尺度上的局部信息, 然后对每个 IMF 进行希尔伯特变换得到瞬时特征量, 再将这些瞬时特征量变换到时-频平面形成希尔伯特谱。经验模态分解方法具有尺度自适应性, 无需事先设定基函数, 而且只在时域对信号进行分析, 在分析非线性非平稳信号方面具有明显优势。王亦斌等人[30]利用 EMD 对水位序列进行分解, 有效地克服了高频噪声对预测结果的不利影响。余周[31]将 EMD 分解出来的 IMF 信号分类重组为高、中、低频信号, 作为深度极限学习机的输入, 提高了水位预测的可靠性和稳定性。潘志浩等人[32]采用了一种“分解-预测-重构”的策略, 对 EMD 分解得到的趋势项和 7 个 IMF 分量分别送入 LSTM 模型, 将每个模型的预测结果相加重构, 得到右江水库日入库流量的预测结果。针对 EMD 的模式混叠问题, Wu 和 Huang [33]提出了一种称为集成经验模式分解(Ensemble Empirical Mode Decomposition, EEMD)的尺度自适应方法, 它通过向信号中添加有限的高斯白噪声来消除模式混叠现象, 从而有效地将非平稳、非线性信号中的 IMF 和残差成份分解出来。Gong 等人[34]基于 EEMD 分解数据进行地下水位预测对比研究, 发现集成经验模态分解比传统的支持向量机、神经网络和自适应模糊推理系统具有更好的预测效果。Wang 等人[35]利用 EEMD 将年径流量时间序列分解, 然后利用 ARIMA (Autoregressive Integrated Moving Average Model)建立预测模型, 发现 EEMD 能明显改善传统 ARIMA 模型的预测精度。

3. 水位预测的机器学习方法

与传统基于物理模型的水位预测方法相比, 基于机器学习的方法着眼于研究当前水位与历史水位数据以及影响水位变化的降雨量和排水量等数据之间的关系, 不需要考虑水文系统的内部物理机制[36], 因此避免了复杂的物理水文过程, 对研究人员的专业知识要求不高[1]。在过去的 30 多年里, 基于机器学习的水位预测方法受到越来越多的关注, 研究人员在这方面做了大量的探索, 提出了各种各样的水位预测方法, 总结起来主要有 5 类: (1) 基于统计模型的方法; (2) 基于灰色理论的方法; (3) 基于传统机器学习的方法; (4) 基于深度神经网络的方法; (5) 基于融合的方法。

3.1. 基于统计模型的预测方法

基于统计模型的预测方法是从统计学的角度出发研究历史水文资料, 主要的研究思路有两种, 一种是寻找影响水位变化的因素, 然后利用这些因素建立水位变化的线性回归预测模型; 另一种是将历史水位的数据看做时间序列, 然后采用时间序列分析技术来预测水位。水位预测的统计模型主要包括线性回归模型、自回归模型和高斯过程。基于线性回归模型的水位预测方法首先采用特征选择的方法, 从各种可能因素中筛选出与水位变化关系密切的因素, 然后建立这些因素与水位变化之间的线性预测模型, Hodgson [37]将降雨和排水量作为多元线性回归变量用于预测地下水位, 提前 6 年模拟南非 Vryburg 地区的地下水位响应。陈志宏[38]利用相关分析法确定了降水量、开采量和前期水位三个影响地下水位的因素, 然后建立线性回归模型来预测地下水位。王盼秋等人[39]通过对山东省淄博市大武水源地 1986 至 2011 年的枯水期水位、降水量和开采量等历史数据进行统计分析, 用历史水位、常年降水量、汛期降水量、开采量、黑旺铁矿排水量、历史补源量和当年补源量 7 个变量建立多元线性回归模型, 对次年指定日期水位进行预测, 得到与实际水位比较吻合的结果。

自回归模型是一种经典的时间序列分析方法, 对于给定的时间序列数据 X , 自回归模型将 t 时刻的值用该时刻之前的一个或多个时刻值的线性组合来表示, 考虑随机误差的影响, 则自回归模型可以表示为 $X_t = c + \sum_{i=1}^p \phi_i X_{t-i} + \varepsilon_t$, 其中 c 是常数项, ε_t 为平均数等于 0 且标准差等于 σ 的标准随机误差。如果考虑 0 到 $t-1$ 每个时刻的随机误差, 则 ε_t 可以表示为 $Z_t \sim N(0, \sigma)$, 则 $X_t = c + \sum_{i=1}^p \phi_i X_{t-i} + Z_t$, 根据该模型, 只要从历史数据中学习到参数 $\phi_i, i=1, 2, \dots, p$, 则可以根据 0 时刻到 $t-1$ 时刻的数据来预测 t 时刻的

序列 X_t 值。自回归移动平均模型(ARIMA)是在自回归模型的基础上引入移动平均项和差分项,它对非平稳时间序列具有良好的预测能力,在水位预测研究中被广泛应用。Ebtehaj [40]等人用 ARIMA 预测马来西亚金马伦高地的 Telom 和 Bertam 两个地方每天水位变化情况。Yu 等人[41]将 ARIMA 模型用于预测长江中游三个站点的日水位,得到较好的效果。陈家辉[42]对原始水位序列数据进行二阶差分处理之后,建立单变量 ARIMA 模型用于西江梧州水文站的短期水位进行预测。余珍[43]基于 2011 至 2015 年长江流域汉口、监利、安庆三个水文站的日平均水位数据分别建立 ARIMA 模型,对 2016 年的水位进行预测,得到比较满意的预测效果。基于自回归模型的水位预测方法的优点是利用水位本身的历史数据就可以实现对未来水位的预测,无需其它的数据,缺点是要求水位序列具有高的自相关性,在数据自相关系数较低时,这种方法难以取得满意的预测结果。

线性回归模型和自回归模型都是建立在变量之间存在线性关系的基础上,它们无法很好地拟合非线性数据和处理噪声。而水位的高低受多种因素的影响,而且它们之间往往存在着复杂的非线性关系,因此研究能够解决非线性关系的水位预测模型具有重要的意义。高斯过程回归是一种基于贝叶斯理论的非参数统计学习模型,它能够处理复杂的非线性关系,在解决像水位这种非平稳时间序列的预测问题方面具有良好的表现。Wang [44]将高斯过程模型用于美国伊利湖水位预测,取得了比当时最先进的水文预报系统更好的效果。Castillo-Boton [45]在水电站大坝水位预测研究中发现,高斯回归过程方法的预测效果优于使用线性核函数的支持向量机模型。苏国韶等人[46]在预测地下水位时,根据河道流量、气温、饱和差、降水量和蒸发量建立高斯过程模型,在小规模数据集上取得比神经网络更好的预测效果。高斯过程回归模型在处理小样本非线性问题方面具有优势,但是它的训练复杂度较高,难以适用于大规模数据的应用场景

3.2. 基于灰色理论的预测方法

灰色系统理论是我国学者邓聚龙于 1982 年提出的[47],用于解决数据不完整的非确定性问题。对于不能用物理模型完整刻画,部分信息未知的系统,利用灰色理论通过对已知的部分信息进行运算,可以实现对系统变化趋势的预测。在时间序列预测方面,灰色理论是通过判断系统中各因素之间发展趋势的关联性,寻找系统变化的内在规律,然后根据这种规律生成相应的数据序列,再建立相关的微分方程模型,进而预测事物未来发展趋势。周振民[48]将 GM(1,1)模型用于地下水位分析和数值模拟,取得良好的预测精度,他们认为 GM(1,1)模型的可操作性较强。卞宁[49]采用灰色系统理论建立了内河航道短期水位预测的 GM(1,1)模型,提高了航道水位预测精度。刘越[50]以历史的降水、蒸发、来水、去水、入渗水量数据为基础数据建立灰色 GM(1,1)模型对白洋淀的地下水位进行预测。杨建飞等人[51]建立灰色残差模型预测宝鸡峡灌区的地下水位,实验结果显示灰色模型能够有效降低数据序列的不稳定而带来的误差。闫英男等人[52]将灰色模型与机器学习方法相结合,较好地预测黑河中游地下水位的变化趋势和波动性。灰色模型无法充分考虑系统的随机性,容易受到外部因素的影响,对周期性较强、波动性大的数据预测效果不太理想,中长期预测精度也较差。

3.3. 基于支持向量机的方法

支持向量机(Support Vector Machine, SVM)是 Vapnik 在 1995 年提出的一种基于统计学习理论的机器学习模型,它采用间隔最大化策略建立结构风险最小化的目标函数,将求解问题转化成一个求解凸二次规划的问题,然后通过求解凸二次规划问题来求得原问题的解。支持向量机模型是建立在数据线性可分的基础上的,当数据线性不可分时,通过引入核函数将数据由低维空间映射到高维空间,将低维空间的非线性问题转换成高维空间的线性可分问题,从而求解问题。支持向量机模型具有坚实的理论基础,在

小样本学习问题上具有良好的表现, 拥有很好的泛化能力, 在很多回归和分类问题中得到成功的应用。Ibrahim [53]采用基于高斯核函数的支持向量机模型对河道水位进行预测, Yoon 等人[54]利用加权误差函数方法来改善支持向量机的递归预测模型, 用于地下水位的长期预测。刘成忠等人[55]利用 PCA (Principal Component Analysis)分析地下水位数据的相关性并提取最佳特征, 然后用支持向量机模型预测地下水位。Kisi [56]在预测湖面水位时采用萤火虫算法搜索支持向量机的超参数, 有效地提前一天预测湖面的水位。朱颖洁[57]利用支持向量机预测西江梧州水文站的日平均水位变化情况, 得到比自回归模型更好的效果。

3.4. 基于深度神经网络的方法

神经网络是一种重要的机器学习方法, 它是一种模拟大脑神经元之间连接结构与信息处理的数学模型, 这种数学模型具有良好的非线性映射和自学习能力[58], 神经网络被广泛应用于水文预测领域的研究。Panyadee [59]将神经网络用于山洪预警系统, 在模型训练过程中用粒子群优化算法获得神经网络的参数, 在泰国北部洪灾区的水位预测中得到 7.82%的测试误差。Phitakwinai [60]将多层感知机模型用于预测泰国清迈市区平河的水位, 采用布谷鸟搜索算法得到的最佳模型在测试数据集上的平均绝对误差为 6.836 cm。高学平[61]将 BP (Back Propagation)神经网络用于调水工程调蓄水位预测, 得到与耦合模型相吻合的结果。余开华[62]将小波分析技术和 BP 神经网络结合起来, 构造小波神经网络模型用于河道流量水位预测, 得到比传统 BP 网络精度较高的结果。李欣[63]根据河流水位的时空信息设计基于 RBF 神经网络的水位预测模型, 实验结果显示这种基于时空序列信息的神经网络模型具有较高的预测精度。这些浅层神经网络虽然在水位预测方面取得一定的效果, 但是对于复杂的水位数据, 浅层神经网络难以充分挖掘隐藏在水位序列中的信息。

极限学习机(extreme learning machine, ELM) [64]是一种单隐藏层的前馈神经网络, 与单层感知机模型和支持向量机这些浅层模型相比具有较高的学习率和较强的泛化能力; 与多层感知机模型相比, ELM 训练时间短、准确度高。Shiri [65]将极限学习机模型用于预测伊朗尔米亚湖的水位, 得到比遗传规划和神经网络更好的预测效果。Yadav [66]比较了极限学习机和支持向量机在观测井水位的预测效果, 结果表明极限学习机具有更好的预测能力。

在传统的 BP 神经网络结构中, 从输入层到隐藏层再到输出层, 层与层之间的节点是全连接的, 而同层的节点之间无连接, 这种结构的网络无法有效处理序列数据。为了解决这种问题, 人们提出了一类特殊结构的神经网络, 即循环神经网络(Recurrent Neural Network, RNN), 这种网络利用循环结构对前面的信息进行记忆、筛选, 并用于当前节点输出的计算中, 在网络结构上通过隐藏层节点的连接来实现, 使得隐藏层的输入不仅包含当前时刻的数据输入, 还包含上一个时刻隐藏层的输出。RNN 在自然语言处理领域的诸多领域, 如词向量表达、词性标注、文本翻译, 已经得到成功应用, 其中最为成功的模型是长短时记忆模型(Long Short-Term Memory, LSTM) [67]和门控循环神经网络(Gated Recurrent Unit, GRU) [68]。

LSTM 是为解决一般 RNN 网络的长期依赖问题而提出来的, 通过引入记忆单元使得网络能够很好的捕获长序列样本数据之间的依赖关系, 具备长期信息记忆功能, 通过遗忘门对历史信息进行选择性地记忆, 这种网络能够很好地解决一般 RNN 的梯度消失和梯度爆炸问题[69], 在水位时间序列预测中得到广泛的关注。Nemilidinne [70]将深度 LSTM 神经网络用于洪水水位预测系统, 倪汉杰[27]将小波分析作为 LSTM 模型的输入, 设计了一个航道水位智能预测模型。Zhang [71]将 LSTM 用于河套农耕区地下水位的预测, 得到比传统神经网络更高的预测精度。GRU 深度神经网络模型是一种结构简单、收敛速度快、映射能力强的循环神经网络, 能够捕获长序列数据之间的长期相关性[72]。潘明阳[73]将 GRU 网络用于长江下游多个水位站的水位预测, 实验结果显示 GRU 模型能够较好地捕获上下游水位的关联性, 取得更高的预测精度。

传统的循环神经网络中每个输入样本对应着一个输出值，但是在序列分析的应用中，往往面临的情况是一个输入序列对应着一个输出序列，针对这种情况，谷歌的研究人员 Sutskever 等人[74]提出了一种称为 seq2seq 的神经网络，seq2seq 网络是一个包含编码器和解码器两部分的网络，编码器中将一个可变长度的输入序列转换为固定长度的向量，称为上下文信息向量，而解码器将上下文信息向量转换为一个输出序列。刘艳[75]将 seq2seq 模型用于预测一段连续时间内的水位，他们在编码器和解码器中都使用了 LSTM 模型，在预测 6 小时、12 小时和 24 小时水位中，取得比传统神经网络和 LSTM 更好的结果。

由于 seq2seq 模型的编码器将输入序列转换成固定长度的语义向量，这个过程会导致序列中某些信息的丢失，为此研究人员在序列数据分析中引入注意力机制，使得模型能够更好地选择序列中的上下文信息。Noor [76]和 Wang [77]提出了基于时空注意力机制的 LSTM 网络模型，用于预测河道水位，得到比传统 LSTM 模型更好的效果。李烈[78]在淮河水位预测研究中，对比分析了不同模型的预测效果，发现 seq2seq 比较适合于预测短期水位，而基于注意力机制的 Informer 和 Autoformer 模型比较适合于预测中长期水位。王迎飞等人[19] [79]在河流水位预测中引入了自适应时空注意力机制，提高了 LSTM 模型的时空信息利用能力。

3.5. 基于融合的方法

在机器学习领域，每种算法有它特定的适用场合，一种算法在某个问题上取得好的效果，在其他问题上不见得也能取得好的效果。为了提高学习器的适应能力，研究人员经常采用融合的方法将多个不同的算法组合起来，形成一个更加强大的学习器。实践表明，融合的方法在很多情况下能够有效减少过拟合，提高模型的泛化能力。在水位预测领域，Zhu 等人[80]将灰色系统理论和神经网络结合起来，建立了灰色系统 - 神经网络联合模型，将 GM(1,1)与 ANN 的输出结果的加权和，用于地下水位预测。Barzegar 等人[81]结合 CNN 网络的特征提取能力和 LSTM 处理序列数据的优势，提出了一种称为 CNN-LSTM 的湖面水位预测模型，得到比单种模型更好的结果；Pan 等人[82]构建一种称为 GRU-CNN 的模型，他们用 GRU 学习水位变化趋势，用卷积神经网络学习不同水位站的空间关系，取得比传统的 ARIMA、LSTM 以及小波神经网络更高的准确率。Miau 等人[83]设计一种将 CNN 和 GRU 连接起来的 Conv-GRU 模型对中国台湾地区某河流的洪水水位进行预测，得到比 LSTM 更好的预测效果；孙英军[84]结合卷积网络和长短期记忆网络，提出一种称为 CNN-Seq2seq 的水位预测方法，有效地提高了河道水位预测的准确性；Nie 等人[85]设计了一种基于注意力机制的水位预测模型 CNN-BiLSTM，他们用 CNN 提取水位数据的空间特征，用 BiLSTM 提取水位数据的周期特征，注意力机制则用于聚焦水位序列中的显著特征，得到比时间卷积网络、支持向量机和 BiLSTM 更高的准确率。刘青松等人[86]提出了一种称为 AR-RNN 的水位预测模型，RNN 用于拟合水位序列中的非线性成分，而 AR 模型用于处理数据中的线性敏感成分，在四川省清溪河流域的水位预测中取得了良好的效果。陈帅宇[87]提出一种称为 ARIMA-CNN-LSTM 的多变量水位预测模型，他们用 CNN 和 LSTM 来学习数据中的非线性特征，用 ARIMA 校正模型的参数，得到比 LSTM 模型、CNN-LSTM 模型、ARIMA 模型以及 BP 神经网络更高的预测精度。总体来说，融合方法能够发挥不同模型是优点，使得集成的模型能够得到更好的预测效果，模型的准确性和可靠性得到提高。

4. 水位序列预测方法的有效性评价

采用机器学习方法进行水位预测就是将预测变量的值输入训练好的模型中，然后经过模型计算之后输出预测时刻的水位值，通过比较预测水位与真实水位之间的差异程度或者计算它们之间的关联程度，就可以衡量预测的效果。度量预测值与真实值之间差异的指标包括平均绝对误差、均方误差、均方根误差和平均绝对百分比误差，衡量预测值与真实值之间的关联程度通常用相关系数来刻画。

平均绝对误差(Mean Absolute Error, MAE): 这个指标计算预测值与真实值之间残差绝对值的平均值, 其计算公式如下,

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t|$$

其中 $e_t = y_t - \hat{y}_t$ 表示 t 时刻的真实水位与预测水位之间的残差, MAE 刻画的是所有预测时刻的残差绝对值的平均, 其值越小说明模型对数据的拟合能力越好。 MAE 的缺点是只有通过指标值的比较才能看出模型的效果。

均方误差(mean squared error, MSE): 这个指标计算的是真实值和预测值残差平方和的均值, 其计算公式如下,

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2$$

MSE 值越小说明拟合效果越好。由于 MSE 与预测变量的量纲不一致, 为了保证量纲一致性, 需要对 MSE 进行开方, 得到均方根误差(Root Mean Squared Error, RMSE)。将均方根误差除以 y 的平均值 $\bar{y}$ 则得到标准化的均方根误差(normalized Root Mean Squared Error, NRMSE)。

平均绝对百分比误差(MAPE, mean absolute percentage error): 这个指标计算残差与真实值之间的相对误差, 其计算公式如下,

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|y_t - \hat{y}_t|}{y_t} \times 100\%$$

这个指标在计算过程中对残差值做了缩放, 使得 $MAPE$ 的值与变量的量纲无关, 能够很好的对尺度不同的时间序列预测模型进行比较。

Perason 相关系数(Pearson Correlation Coefficient, PCC): 这个指标计算两个变量之间是线性相关程度, 其计算公式如下,

$$R = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}}$$

R 的取值范围为 $[-1, 1]$, $R < 0$ 表示随机变量 x 与 y 呈负相关关系, $R > 0$ 表示 x 与 y 呈正相关关系, $|R|$ 的值越接近 1 表示随机变量 x 与 y 之间的相关程度越高, 否则相关程度越低。

表 1 列出了水位预测研究中的特征分析方法、预测模型, 以及评价指标。

Table 1. The feature analysis method, prediction model and evaluation index in previous research
表 1. 以往研究方法中的特征分析方法、预测模型, 以及评价指标

序号	作者(时间)	特征分析方法	预测方法	评价指标
1	Das (2016)	相关分析	hybrid Bayesian network	RMSE, MAE, NRMSD, R^2 , PCC
2	马森标(2022)	相关分析	LSTM-Attention	MSE, R^2 , RMSE, MAE
3	陈志宏(1999), 王盼秋(2015)	相关分析	多元线性回归模型	PCC, MAPE, F 检验
4	余珍(2018)	自相关和偏自相关分析	ARIMA	RSME, MAPE
5	刘越(2010)	相关分析	灰色系统, 神经网络	相对误差, 平均相对误差
6	卞宁(2018)	相关分析	灰色系统	AME, MRE

续表

7	Choi (2019)	互信息	ANN, DT, RF, SVM	PCC, RMSE, NSE, PI
8	Wang (2020), Castillo-Boton (2020)	互熵	GP, MLR, MLP, RF, NN	RMSE, MAE
9	Hou (1991), Tu (2021)	调和分析	sequential algorithm, LSTM	RMSE, R^2
10	余开华(2013), Adamowski (2011), Wang (2020)	小波分解	Neuro-fuzzy systems, wavelet ANN	RMSE, MAE, CE
11	Gong (2018)	经验模式分解	ANN, SVM	RMSE, NS, AIC
12	Wang (2015)	集合经验模式分解	ARIMA	RMSE, MAPE, R^2 , NS
13	刘成忠(2011), Ibrahim (2014), 朱颖洁(2022)	PCA	SVR, ANN, 自回归	MSECV, MSE, UCI
14	Phitakwinai (2016), Panyadee (2017)	—	ANN	MSE, MAPE
15	Shiri (2016), Yadav (2017)	—	ELM	RMSE, PCC, R^2
16	Zhang (2018)	回归分析	LSTM	R^2 , RMSE
17	陈睿鹤(2018)	小波分析	GRU	MAE, RMSE, PCC, NSE
18	潘明阳(2020)	关联分析	GRU	MRE
19	王迎飞(2022)	注意力机制, 互信息	LSTM	MA, RMSE, MAPE, R^2

注: Coefficient of efficiency: CE; Gaussian process: GP; Multiple linear regression: MLR; Multilayer perceptron: MLP; Random forest: RF; Mean relative error: MRE; Absolute mean error: AME; Mean squared error of cross-validation: MSECV; Nash-Sutcliffe efficiency coefficient: NSE; Extreme Learning Machine: ELM.

5. 结论与研究展望

在过去的三十多年里, 研究人员在湖泊、江河、水库和地下水的水位预测方面做了大量的探索, 取得了一些重要的进步, 主要表现在如下几个方面: (1) 数据越来越丰富。越来越多的水文站安装了各种水位测量设备, 加上遥感遥测技术的发展, 使得我们能够获取各种相关数据, 可以对水位的变化规律进行深入的分析与建模。(2) 研究方法越来越高级。在特征选择和提取方面, 从线性相关系数到基于互信息的选择, 从 PCA 变换到小波变换的特征提取; 在预测模型方面, 从早期的简单线性回归模型到高斯回归过程, 从多层感知机模型到深度神经网络, 不断地加深对水位变化规律的了解和认识。(3) 一些水位预测系统已经建立, 越来越多的研究成果被用于实际的水位预测应用中, 这使得理论研究逐渐接近实际应用。

尽管水位预测研究在数据积累、研究方法和应用系统开发方面取得了一些进展, 这方面的研究仍然存在一些挑战。(1) 大数据的挑战。随着科学技术的发展, 积累的气象、水文数据越来越多, 如何从海量的数据中挖掘出水位变化的规律, 将是这一研究领域人员不得不面对的问题。(2) 中长期预测精度不高。水位预测从时间角度可以分为短期预测和中长期预测, 短期预测一般以分钟、小时或天为预测周期, 中长期预测一般是以周、月或年为单位, 目前的预测方法一般在短期水位预测方面能够达到比较高的预测精度, 但是对于中长期水位预测来说, 还是一件困难的事情。(3) 模型的可解释程度不高。目前水位预测的多数机器学习方法是基于历史水位的序列数据, 关注的焦点是历史水位数据本身的变化趋势和随机变动方面的因素, 而对影响水位变化的因素, 如降水、蒸发量、上下游水位、水文、水动力等方面, 考虑的不多, 这些方面的信息用得很少, 使得预测模型的可解释性不高。

未来水位预测研究应该重点解决如下几个问题: (1) 加强时间序列特征分析。不同的时间序列数据分

析技术可以提取数据中不同成分的信息, 这些不同成分的信息从不同角度刻画时间序列的内在规律, 由于神经网络自身具有特征抽取的能力, 未来的研究可以考虑将神经网络与传统的调和分析、小波分析和经验模式分解等方法结合起来, 从中提取更加有利于水位预测的特征。(2) 多源数据融合研究。影响水位的因素复杂而多样, 未来的研究应该注重收集各种可能影响水位变化的数据, 将这些不同来源的数据有效地利用起来, 将有利于提高水位预测的准确性和可靠性。(3) 加强多学科融合研究。水位的变化受到天气、水文等多种因素影响, 水位预测本质上是一个多学科交叉的工作, 将机器学习技术与气象、水文等学科知识结合起来, 有利于更好地刻画水位变换的规律, 从而提高水位预测的准确度和时效性。

参考文献

- [1] Mosavi, A., Ozturk, P. and Chau, K. (2018) Flood Prediction Using Machine Learning Models: Literature Review. *Water*, **10**, Article 1536. <https://doi.org/10.3390/w10111536>
- [2] 周涵. 多模型融合的黑河流域地下水水位预测方法研究[D]: [硕士学位论文]. 北京: 中国石油大学, 2020.
- [3] 马森标, 唐卫明, 陈春强. LSTM 优化模型的水库水位预测研究[J]. 福建电脑, 2022, 38(5): 1-8.
- [4] Zhao, M. and Hendon, H.H. (2009) Representation and Prediction of the Indian Ocean Dipole in the POAMA Seasonal Forecast Model. *Quarterly Journal of the Royal Meteorological Society*, **135**, 337-352. <https://doi.org/10.1002/qj.370>
- [5] 李铭鹏. 覆盖型岩溶地基基础处理方法的探索[D]: [硕士学位论文]. 深圳: 深圳大学, 2017.
- [6] 许江涛. 地下水数值模拟及其三维可视化技术的研究与应用[D]: [硕士学位论文]. 焦作: 河南理工大学, 2009.
- [7] Cunningham, A.B. and Sinclair, P.J. (1979) Application and Analysis of a Coupled Surface and Groundwater Model. In: *Developments in Water Science*, Elsevier, 129-148. [https://doi.org/10.1016/s0167-5648\(09\)70014-0](https://doi.org/10.1016/s0167-5648(09)70014-0)
- [8] 李永凯, 王拓, 肖晒. 水力学耦合水文学模型在沮漳河河溶水文站洪水水位预报的应用研究[J]. 水资源开发与管理, 2020(6): 4-8.
- [9] 李加龙, 李慧赞, 罗澈葱, 等. 抚仙湖历史水位反演与未来 30 年水位变化预测[J]. 湖泊科学, 2022, 34(3): 958-971.
- [10] Lai, X., Jiang, J., Liang, Q. and Huang, Q. (2013) Large-Scale Hydrodynamic Modeling of the Middle Yangtze River Basin with Complex River-Lake Interactions. *Journal of Hydrology*, **492**, 228-243. <https://doi.org/10.1016/j.jhydrol.2013.03.049>
- [11] Rajaei, T., Ebrahimi, H. and Nourani, V. (2019) A Review of the Artificial Intelligence Methods in Groundwater Level Modeling. *Journal of Hydrology*, **572**, 336-351. <https://doi.org/10.1016/j.jhydrol.2018.12.037>
- [12] Sánchez-Maróño, N., Alonso-Betanzos, A. and Tombilla-Sanromán, M. (2007) Filter Methods for Feature Selection—A Comparative Study. In: *Lecture Notes in Computer Science*, Springer, 178-187. https://doi.org/10.1007/978-3-540-77226-2_19
- [13] Kohavi, R. and John, G.H. (1997) Wrappers for Feature Subset Selection. *Artificial Intelligence*, **97**, 273-324. [https://doi.org/10.1016/s0004-3702\(97\)00043-x](https://doi.org/10.1016/s0004-3702(97)00043-x)
- [14] Blum, A.L. and Langley, P. (1997) Selection of Relevant Features and Examples in Machine Learning. *Artificial Intelligence*, **97**, 245-271. [https://doi.org/10.1016/s0004-3702\(97\)00063-5](https://doi.org/10.1016/s0004-3702(97)00063-5)
- [15] Lal, T.N., Chapelle, O., Weston, J. and Elisseeff, A. (2006) Embedded Methods. In: *Studies in Fuzziness and Soft Computing*, Springer, 137-165. https://doi.org/10.1007/978-3-540-35488-8_6
- [16] Das, M., Ghosh, S.K., Chowdary, V.M., Saikrishnaveni, A. and Sharma, R.K. (2016) A Probabilistic Nonlinear Model for Forecasting Daily Water Level in Reservoir. *Water Resources Management*, **30**, 3107-3122. <https://doi.org/10.1007/s11269-016-1334-6>
- [17] Liu, H. and Motoda, H. (1998) Feature Selection for Knowledge Discovery and Data Mining. Kluwer Academic Publishers.
- [18] Choi, C., Kim, J., Han, H., Han, D. and Kim, H.S. (2019) Development of Water Level Prediction Models Using Machine Learning in Wetlands: A Case Study of Upo Wetland in South Korea. *Water*, **12**, Article 93. <https://doi.org/10.3390/w12010093>
- [19] 王迎飞, 黄应平, 肖敏, 等. 基于注意力机制的 LSTM 长江汛期水位预测方法研究[J]. 三峡大学学报: 自然科学版, 2022, 44(3): 13-19.
- [20] El-Diasty, M., Al-Harbi, S. and Pagiatakis, S. (2018) Hybrid Harmonic Analysis and Wavelet Network Model for Sea Water Level Prediction. *Applied Ocean Research*, **70**, 14-21. <https://doi.org/10.1016/j.apor.2017.11.007>

- [21] Hou, T.H. (1991) Sequential Tidal Analysis and Prediction. Ph.D. Thesis, University of New Brunswick.
- [22] Li, Y., Peng, G., Chen, P., Chen, K., Li, R. and Song, Z. (2022) Harmonic Analysis of Short-Term Tidal Level Prediction Model for Tidal Reaches. *Arabian Journal of Geosciences*, **15**, Article No. 473. <https://doi.org/10.1007/s12517-022-09757-1>
- [23] Tu, Z., Gao, X., Xu, J., Sun, W., Sun, Y. and Su, D. (2021) A Novel Method for Regional Short-Term Forecasting of Water Level. *Water*, **13**, Article 820. <https://doi.org/10.3390/w13060820>
- [24] Wang, B., Wang, B., Wu, W., Xi, C. and Wang, J. (2020) Sea-Water-Level Prediction via Combined Wavelet Decomposition, Neuro-Fuzzy and Neural Networks Using SLA and Wind Information. *Acta Oceanologica Sinica*, **39**, 157-167. <https://doi.org/10.1007/s13131-020-1569-1>
- [25] Malekzadeh, M., Kardar, S., Saeb, K., Shabanlou, S. and Taghavi, L. (2019) A Novel Approach for Prediction of Monthly Ground Water Level Using a Hybrid Wavelet and Non-Tuned Self-Adaptive Machine Learning Model. *Water Resources Management*, **33**, 1609-1628. <https://doi.org/10.1007/s11269-019-2193-8>
- [26] Adamowski, J. and Chan, H.F. (2011) A Wavelet Neural Network Conjunction Model for Groundwater Level Forecasting. *Journal of Hydrology*, **407**, 28-40. <https://doi.org/10.1016/j.jhydrol.2011.06.013>
- [27] 倪汉杰, 蒋仲廉, 初秀民, 钟诚. 基于 DWT-LSTM 的航道水位智能预测模型研究[J]. 中国航海, 2021, 44(2): 97-102.
- [28] 刘立燕. 基于 Copula 函数和神经网络模型的洪水预测[D]: [硕士学位论文]. 南京: 南京邮电大学, 2018.
- [29] Huang, N.E., Shen, Z., Long, S.R., Wu, M.C., Shih, H.H., Zheng, Q., *et al.* (1998) The Empirical Mode Decomposition and the Hilbert Spectrum for Nonlinear and Non-Stationary Time Series Analysis. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, **454**, 903-995. <https://doi.org/10.1098/rspa.1998.0193>
- [30] 王亦斌, 孙涛, 梁雪春, 谢海洋. 基于 EMD-LSTM 模型的河流水量水位预测[J]. 水利水电科技进展, 2020, 40(6): 40-47.
- [31] 余周, 姜涛, 范鹏辉, 牛超群, 陈兵. 基于 EMD-DELM-LSTM 组合模型的湖泊水位多时间尺度预测[J]. 长江科学院院报, 2024, 41(6): 28-35.
- [32] 潘志浩, 陈森林, 梁斌, 等. 基于 EMD-LSTM 模型的右江水库日入库流量预测[J]. 水资源研究, 2022, 11(1): 20-29.
- [33] Wu, Z. And Huang, N.E. (2009) Ensemble Empirical Mode Decomposition: A Noise-Assisted Data Analysis Method. *Advances in Adaptive Data Analysis*, **1**, 1-41. <https://doi.org/10.1142/s1793536909000047>
- [34] Gong, Y., Wang, Z., Xu, G. and Zhang, Z. (2018) A Comparative Study of Groundwater Level Forecasting Using Data-Driven Models Based on Ensemble Empirical Mode Decomposition. *Water*, **10**, Article 730. <https://doi.org/10.3390/w10060730>
- [35] Wang, W., Chau, K., Xu, D. and Chen, X. (2015) Improving Forecasting Accuracy of Annual Runoff Time Series Using ARIMA Based on EEMD Decomposition. *Water Resources Management*, **29**, 2655-2675. <https://doi.org/10.1007/s11269-015-0962-6>
- [36] Rajaei, T. and Boroumand, A. (2015) Forecasting of Chlorophyll-A Concentrations in South San Francisco Bay Using Five Different Models. *Applied Ocean Research*, **53**, 208-217. <https://doi.org/10.1016/j.apor.2015.09.001>
- [37] Hodgson, F.D.I. (1978) The Use of Multiple Linear Regression in Simulating Ground-Water Level Responses. *Groundwater*, **16**, 249-253. <https://doi.org/10.1111/j.1745-6584.1978.tb03232.x>
- [38] 陈志宏. 多元线性回归方法在地下水水位预测中的应用[J]. 北京地质, 1999, 11(3): 20-26.
- [39] 王盼秋, 曾丹, 孟凡宇. 回归分析法在水位预测中的应用[J], 山东水利, 2015(3): 29-31.
- [40] Ebtehaj, I., Sammen, S.S., Sidek, L.M., Malik, A., Sihag, P., Al-Janabi, A.M.S., *et al.* (2021) Prediction of Daily Water Level Using New Hybridized GS-GMDH and ANFIS-FCM Models. *Engineering Applications of Computational Fluid Mechanics*, **15**, 1343-1361. <https://doi.org/10.1080/19942060.2021.1966837>
- [41] Yu, Z., Lei, G., Jiang, Z. and Liu, F. (2017) ARIMA Modelling and Forecasting of Water Level in the Middle Reach of the Yangtze River. 2017 4th International Conference on Transportation Information and Safety (ICTIS), Banff, 8-10 August 2017, 172-177. <https://doi.org/10.1109/ictis.2017.8047762>
- [42] 陈家辉, 李敏. 基于 ARIMA 模型的西江梧州下游段通航水位预测研究[J]. 西部交通科技, 2022(7): 200-203.
- [43] 余珍. 基于时间序列分析的航道水位预测研究[J]. 中国水运(下半月), 2018, 18(10): 148-150.
- [44] Wang, Q. and Wang, S. (2020) Machine Learning-Based Water Level Prediction in Lake Erie. *Water*, **12**, Article 2654. <https://doi.org/10.3390/w12102654>
- [45] Castillo-Botón, C., Casillas-Pérez, D., Casanova-Mateo, C., Moreno-Saavedra, L.M., Morales-Díaz, B., Sanz-Justo, J.,

- et al.* (2020) Analysis and Prediction of Dammed Water Level in a Hydropower Reservoir Using Machine Learning and Persistence-Based Techniques. *Water*, **12**, Article 1528. <https://doi.org/10.3390/w12061528>
- [46] 苏国韶, 张研, 张小飞. 高斯过程机器学习方法在地下水位预测中的应用[J]. 中国农村水利水电, 2008(12): 48-50.
- [47] Ju-Long, D. (1982) Control Problems of Grey Systems. *Systems & Control Letters*, **1**, 288-294. [https://doi.org/10.1016/s0167-6911\(82\)80025-x](https://doi.org/10.1016/s0167-6911(82)80025-x)
- [48] 周振民, 赵明亮, 李玲. GM(1,1)模型在滦河下游地区地下水位预测中的应用[J]. 中国农村水利水电, 2011(2): 50-52.
- [49] 卞宁. 改进型灰色系统在航道水位预测中的应用[J]. 中国水运, 2018(5): 75-80.
- [50] 刘越. 白洋淀周边地下水数量分析及水位预测[D]: [硕士学位论文]. 保定: 河北农业大学, 2010.
- [51] 杨建飞, 刘俊民, 陈琳. 基于灰色残差模型的灌区地下水最小埋深预测[J]. 人民黄河, 2011, 33(7): 107-108.
- [52] 闫英男. 基于灰色理论与机器学习的黑河地下水水位预测研究[D]: [硕士学位论文]. 兰州: 兰州大学, 2018.
- [53] Ibrahim, N., Wibowo, A. (2014) Support Vector Regression with Missing Data Treatment Based Variables Selection for Water Level Prediction of Galas River in Kelantan Malaysia. *WSEAS Transactions on Mathematics Archive*, **13**, 69-78.
- [54] Yoon, H., Hyun, Y., Ha, K., Lee, K. and Kim, G. (2016) A Method to Improve the Stability and Accuracy of ANN- and SVM-Based Time Series Models for Long-Term Groundwater Level Predictions. *Computers & Geosciences*, **90**, 144-155. <https://doi.org/10.1016/j.cageo.2016.03.002>
- [55] 刘成忠, 黄高宝, 韩建民. 基于 PCA 特征提取的 SVR 地下水位动态预测方法[J]. 工程勘察, 2011, 39(3): 36-39.
- [56] Kisi, O., Shiri, J., Karimi, S., Shamshirband, S., Motamedi, S., Petković, D., *et al.* (2015) A Survey of Water Level Fluctuation Predicting in Urmia Lake Using Support Vector Machine with Firefly Algorithm. *Applied Mathematics and Computation*, **270**, 731-743. <https://doi.org/10.1016/j.amc.2015.08.085>
- [57] 朱颖洁. 西江梧州站基于支持向量机的水位预测模型研究[J]. 广东水利水电, 2022(11): 39-42.
- [58] 赵新宇, 费良军. LM 算法的神经网络在灌区地下水位预测中的应用研究[J]. 沈阳农业大学学报, 2006, 37(2): 213-216.
- [59] Panyadee, P., Champrasert, P. and Aryupong, C. (2017) Water Level Prediction Using Artificial Neural Network with Particle Swarm Optimization Model. 2017 5th International Conference on Information and Communication Technology (ICoICT), Melaka, 17-19 May 2017, 1-6. <https://doi.org/10.1109/icoict.2017.8074670>
- [60] Phitakwinai, S., Auephanwiriyakul, S. and Theera-Umpon, N. (2016) Multilayer Perceptron with Cuckoo Search in Water Level Prediction for Flood Forecasting. 2016 International Joint Conference on Neural Networks (IJCNN), Vancouver, 24-29 July 2016, 519-524. <https://doi.org/10.1109/ijcnn.2016.7727243>
- [61] 高学平, 闫晨丹, 张岩, 孙博闻. 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.
- [62] 余开华. 小波神经网络模型在河道流量水位预测中的应用[J]. 水资源与水工程学报, 2013(2): 204-208.
- [63] 李欣, 王超, 赵虎川. 基于时空序列模型的 RBF 神经网络在河流水位预测中的应用[J]. 城市勘测, 2016(5): 34-39.
- [64] Huang, G., Zhu, Q. and Siew, C. (2006) Extreme Learning Machine: Theory and Applications. *Neurocomputing*, **70**, 489-501. <https://doi.org/10.1016/j.neucom.2005.12.126>
- [65] Shiri, J., Shamshirband, S., Kisi, O., Karimi, S., Bateni, S.M., Hosseini Nezhad, S.H., *et al.* (2016) Prediction of Water-Level in the Urmia Lake Using the Extreme Learning Machine Approach. *Water Resources Management*, **30**, 5217-5229. <https://doi.org/10.1007/s11269-016-1480-x>
- [66] Yadav, B., Ch, S., Mathur, S. and Adamowski, J. (2017) Assessing the Suitability of Extreme Learning Machines (ELM) for Groundwater Level Prediction. *Journal of Water and Land Development*, **32**, 103-112. <https://doi.org/10.1515/jwld-2017-0012>
- [67] Hochreiter, S. and Schmidhuber, J. (1997) Long Short-Term Memory. *Neural Computation*, **9**, 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- [68] Cho, K., van Merriënboer, B., Bahdanau, D. and Bengio, Y. (2014). On the Properties of Neural Machine Translation: Encoder-Decoder Approaches. *Proceedings of SSSST-8, Eighth Workshop on Syntax, Semantics and Structure in Statistical Translation*, Doha, October 2014, 103-111. <https://doi.org/10.3115/v1/w14-4012>
- [69] Zhao, Z., Chen, W., Wu, X., Chen, P.C.Y. and Liu, J. (2017) LSTM Network: A Deep Learning Approach for Short-Term Traffic Forecast. *IET Intelligent Transport Systems*, **11**, 68-75. <https://doi.org/10.1049/iet-its.2016.0208>
- [70] Anusha, N. (2019) Data Driven Approaches for Water Level Prediction. Ph.D. Thesis, University of Houston.

-
- [71] Zhang, J., Zhu, Y., Zhang, X., Ye, M. and Yang, J. (2018) Developing a Long Short-Term Memory (LSTM) Based Model for Predicting Water Table Depth in Agricultural Areas. *Journal of Hydrology*, **561**, 918-929. <https://doi.org/10.1016/j.jhydrol.2018.04.065>
 - [72] 陈睿鹤. 基于小波变换和 GRU 深度神经网络的地下水位预测研究[D]: [硕士学位论文]. 武汉: 华中科技大学, 2018.
 - [73] 潘明阳, 周海南, 李增辉, 等. 智能水位预测服务系统研究[J]. 大连海事大学学报, 2020, 46(3): 31-37.
 - [74] Sutskever, I., Vinyals, O. and Le, Q.V. (2014) Sequence to Sequence Learning with Neural Networks.
 - [75] 刘艳, 张婷, 康爱卿, 等. 基于 Seq2Seq 模型的短期水位预测[J]. 水利水电科技进展, 2022(3): 57-63.
 - [76] Noor, F., Haq, S., Rakib, M., Ahmed, T., Jamal, Z., Siam, Z.S., *et al.* (2022) Water Level Forecasting Using Spatiotemporal Attention-Based Long Short-Term Memory Network. *Water*, **14**, Article 612. <https://doi.org/10.3390/w14040612>
 - [77] Wang, Y., Huang, Y., Xiao, M., Zhou, S., Xiong, B. and Jin, Z. (2023) Medium-Long-Term Prediction of Water Level Based on an Improved Spatio-Temporal Attention Mechanism for Long Short-Term Memory Networks. *Journal of Hydrology*, **618**, Article 129163. <https://doi.org/10.1016/j.jhydrol.2023.129163>
 - [78] 李烈. 机器学习方法在淮河水位预测中的应用[D]: [硕士学位论文]. 蚌埠: 安徽财经大学, 2022.
 - [79] 王迎飞. 基于自适应时空注意力机制的河流水位预测研究[D]: [硕士学位论文]. 宜昌: 三峡大学, 2022.
 - [80] Changjun Zhu, and Qin Ju, (2009) United Grey System-Neural Network Model and Its Application in Prediction of Groundwater Level. 2009 *International Conference on Industrial Mechatronics and Automation*, Chengdu, 15-16 May 2009, 434-437. <https://doi.org/10.1109/icima.2009.5156656>
 - [81] Barzegar, R., Aalami, M.T. and Adamowski, J. (2021) Coupling a Hybrid CNN-LSTM Deep Learning Model with a Boundary Corrected Maximal Overlap Discrete Wavelet Transform for Multiscale Lake Water Level Forecasting. *Journal of Hydrology*, **598**, Article 126196. <https://doi.org/10.1016/j.jhydrol.2021.126196>
 - [82] Pan, M., Zhou, H., Cao, J., Liu, Y., Hao, J., Li, S., *et al.* (2020) Water Level Prediction Model Based on GRU and CNN. *IEEE Access*, **8**, 60090-60100. <https://doi.org/10.1109/access.2020.2982433>
 - [83] Miao, S. and Hung, W. (2020) River Flooding Forecasting and Anomaly Detection Based on Deep Learning. *IEEE Access*, **8**, 198384-198402. <https://doi.org/10.1109/access.2020.3034875>
 - [84] 孙英军, 唐为昊, 王成, 李英德. 基于 CNN-Seq2seq 的河道水位区间预测方法[J]. 浙江工业大学学报, 2022, 50(4): 381-392.
 - [85] Nie, Q., Wan, D. and Wang, R. (2021) CNN-BiLSTM Water Level Prediction Method with Attention Mechanism. *Journal of Physics: Conference Series*, **2078**, Article 012032. <https://doi.org/10.1088/1742-6596/2078/1/012032>
 - [86] 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.
 - [87] 陈帅宇, 赵龔骧, 蒋磊. 基于 ARIMA-CNN-LSTM 模型的黄河开封段水位预测研究[J]. 水利水电快报, 2023, 44(1): 15-22.