

基于 CNN-Attention-LSTM 模型的地下水水位预测

李小根¹, 刘泓辰¹, 付景保², 王安明¹, 毛新宇¹

(1. 华北水利水电大学地球科学与工程学院, 河南 郑州 450046; 2. 河南工程学院环境与生物工程学院, 河南 郑州 451191)

摘要: 为了提高地下水水位预测的准确性和稳定性, 构建了一种基于卷积神经网络 (CNN)、注意力机制 (Attention) 和长短期记忆网络 (LSTM) 的 CNN-Attention-LSTM 模型应用于地下水水位预测, 采用河南省某市 17 处观测井的实测数据对模型进行了验证, 并与 CNN、LSTM、CNN-LSTM、Attention-LSTM 模型进行对比分析。结果表明: CNN-Attention-LSTM 模型在各井位上测试集平均决定系数、平均绝对误差、均方根误差分别为 0.972、0.074 和 0.083, 相较于 CNN、LSTM、CNN-LSTM、Attention-LSTM 模型, 该模型具有较好的平均决定系数、平均绝对误差和均方根误差指标; 结合 CNN、Attention 和 LSTM 模型应用于地下水水位预测, 可实现优势互补, 提高水位预测的准确性和稳定性。

关键词: 地下水; 水位预测; CNN-Attention-LSTM 模型; 河南省

中图分类号: TV311.8

文献标志码: A

文章编号: 1004-6933(2025)04-0228-08

Groundwater level prediction based on CNN-Attention-LSTM model//LI Xiaogen¹, LIU Hongchen¹, FU Jingbao², WANG Anming¹, MAO Xinyu¹ (1. College of Geosciences and Engineering, North China University of Water Resources and Electric Power, Zhengzhou 450046, China; 2. College of Environment and Biological Engineering, Henan University of Engineering, Zhengzhou 451191, China)

Abstract: In order to improve the accuracy and stability of groundwater level prediction, a CNN-Attention-LSTM model based on convolutional neural network (CNN), attention mechanism (Attention), and long short-term memory network (LSTM) was applied to groundwater level prediction. The model was verified through the measured data from 17 observation wells in a certain city of Henan Province, and was compared and analyzed with CNN, LSTM, CNN-LSTM, and Attention-LSTM models. The results show that the average determination coefficient, average absolute error, and root mean square error of the test set for each well position of the CNN-Attention-LSTM model are 0.972, 0.074, and 0.083, respectively. Compared with CNN, LSTM, CNN-LSTM, and Attention-LSTM models, this model has better average determination coefficient, average absolute error, and root mean square error indicators. Combining the CNN, Attention, and LSTM models for groundwater level prediction can achieve complementary advantages and improve the accuracy and stability of water level prediction.

Key words: groundwater; water level prediction; CNN-Attention-LSTM model; Henan Province

随着社会经济的快速发展, 大量污染物无序排放, 导致地下水呈现大面积、复合型的污染特征, 地下水环境整体不容乐观^[1]。国家高度重视地下水资源与环境保护, 做好相关工程的环境影响评价工作对地下水环境保护意义重大^[2]。地下水水位预测对于水资源管理、农业生产和环境保护等具有重要意义: ①能够赋能管理者有效规划和管理水资源, 规避地下水枯竭和过度开采问题, 优化抽取地下水

策略; ②指导农业灌溉决策, 防止因过度灌溉导致地下水水位下降和土壤盐渍化, 确保农作物的水分供给; ③精准识别地下水污染和盐水入侵的风险, 进而采取措施保护湿地、河流和湖泊等与地下水相关的生态系统。

由于地下水水位受地质条件、水文特征、降水量和蒸发量等多种复杂因素的影响, 且地下水系统本身具有时空变化趋势和周期性变化等不确定特性,

基金项目: 国家自然科学基金项目 (42377490, 42077449); 河南省重大科技专项项目 (221100320200); 河南省研究生教育改革与质量提升工程项目 (YJS2024JC03, YJS2024KC01); 华北水利水电大学研究生教育改革与质量提升工程项目 (NCWUJPC202302, NCWUYZKC202305)

作者简介: 李小根 (1973—), 男, 教授, 博士, 主要从事地理信息系统与水利信息技术研究。E-mail: lixiaogen@ncwu.edu.cn

通信作者: 付景保 (1966—), 男, 教授, 硕士, 主要从事区域生态环境保护与可持续发展研究。E-mail: fujingbao@126.com

需要综合考虑这些因素进行空间建模^[3]。为了提高地下水水位预测的准确性,选择合适的预测模型至关重要^[4]。目前常用的水位预测模型包括:①物理模型^[5]。依赖地下水流方程和相应的边界条件,通过数值方法预测地下水水位。如 GDBH 分布式水文模型^[6]和 MODFLOW^[7]。②时间序列模型^[8-11]。通过分析历史水位数据的时间序列特征,利用自回归和移动平均关系,预测未来水位的变化趋势^[12]。然而,上述两种传统预测方法在捕捉地下水水位数据的时空依赖性和非线性关系方面存在一定的局限性^[13]。③机器学习模型^[14-17]。在地下水水位预测中能够捕捉复杂的非线性关系,通常具有较高的预测精度和自动特征提取能力,且适应性强。Wunsch 等^[18-19]基于德国全国范围内的 118 眼监测井观测水位,采用卷积神经网络(convolutional neural network, CNN)预测了截至 21 世纪末德国全境的地下水水位变化趋势。张朝逢等^[20]利用长短时记忆网络(long short-term memory, LSTM)预测陕西关中平原 33 眼观测井的地下水埋深。结果表明,样本容量越大、训练次数适宜(40 次),预测精度越高。闫佰忠等^[21]将多变量 LSTM 用于泰安市岱岳区地下水水位预测,考虑时序和影响因素,预测精度明显高于单变量 LSTM 和 BP 神经网络。但机器学习模型对数据量和计算资源的需求较高,且存在过拟合风险及黑箱特性,影响了模型的可解释性。④混合模型^[22-23]。在地下水水位预测中结合了多种方法的优势,能够有效整合不同数据源和模型。冯鹏宇等^[24]结合 CNN 提取长江水位数据的空间关联性和门控循环单元(GRU)捕捉的时序关联性,提升了水位预测精度。Wei 等^[25]利用小波变换和相空间重构对地下水水位时间序列进行分解和重构,并结合人工神经网络模型构建预测模型,取得了优于传统神经网络模型的预测精度。佃松宜等^[26]提出了一种融合空间和时间注意机制的鲁棒自适应水位预测算法,通过预处理和权重调整,提高了在复杂数据环境下的预测精度,展现了其良好的自适应性和鲁棒性。

依靠简单的物理模型、时间序列模型或机器学习模型难以有效提取特征与地下水水位之间的关联性,且难以达到所需的预测精度。在选择合理的模型和调优参数的前提下,混合模型能够有效整合不同数据和模型,提高地下水水位预测的准确性和稳定性。本文将一种基于卷积神经网络(CNN)、注意力(Attention)机制和长短时记忆网络(LSTM)的 CNN-Attention-LSTM 模型应用于地下水水位预测,利用河南省某市 1999—2008 年的地下水水位数据,

对该市地下水水位进行了预测和分析,并采用 LSTM、CNN、Attention-LSTM、CNN-LSTM 模型进行对比试验,以验证 CNN-Attention-LSTM 模型在地下水水位预测中的优越性。

1 模型构建

1.1 CNN

利用 CNN 卷积层和池化层,对温度、降水量、蒸发量和前期水位影响因子进行特征提取。通过卷积层,网络能够有效识别各输入之间的潜在局部依赖关系。卷积层操作表示为

$$C(t) = \sum_{a=0}^{n-1} x(t+a)w(a) + b \quad (1)$$

式中: $C(t)$ 为在时间步 t 处的卷积层输出; $x(t)$ 为在时间步 t 处输入序列的值; $w(a)$ 为位置 a 处卷积核的权重; b 为偏置项; n 为卷积核的大小。

池化层对提取的特征进行降维,保留最显著的信息,抑制噪声和干扰。卷积层操作产生的高维度特征图将增加网络的复杂度和训练成本,池化层的降采样技术能有效应对这一问题,它将特征图中的相邻区域合并为一个值,其中最大池化取区域内的最大值,而平均池化则取区域内的平均值。该方法能有效缩小特征图的尺寸,同时保留重要特征信息,从而提高计算效率并降低成本。经过处理得到的特征数据为后续分析和建模提供了坚实的基础。

1.2 注意力机制

注意力机制是一种能够合理分配信息权重的结构,通过计算输入数据中各影响因子间的关系,对模型预测结果相关性大的特征赋予高权重,而对相关性小的特征赋予低权重^[27]。因此,处理复杂的时间序列地下水水位数据时,注意力机制能够显著提升性能,促进更深入的数据挖掘和分析。将其应用于地下水水位预测,能够重点聚焦对预测结果有重要影响的特征,提高预测结果的准确性和可解释性。

在全连接层中,模型计算出给定时间步 t 的元素分配重要性得分。随后,利用 Softmax 函数对上一阶段的输出值进行归一化处理,得到注意力权重。最后,通过将注意力权重与输入序列加权,得到时间步 t 上根据注意力权重进行加权的输入序列。

1.3 LSTM

LSTM 是一种特殊的循环神经网络(recurrent neural network, RNN)。与标准 RNN 不同,LSTM 具有特殊的记忆单元,能够学习长期依赖关系,同时避免梯度消失或爆炸问题。LSTM 为处理时间序列数据而设计。时间序列数据通常具有时间依赖性和复杂性,LSTM 的结构能够有效捕捉时间序列中的长

期依赖关系。

LSTM 由多个神经元组成,每个神经元均包含输入门、遗忘门和输出门。

1.4 CNN-Attention-LSTM 模型

结合 CNN、LSTM 和 Attention 机制的优点, CNN-Attention-LSTM 模型适用于长短期趋势的多变量时间序列预测,其结构如图 1 所示,主要由 3 部分组成:CNN 层、注意力层和 LSTM 层。CNN 层中的卷积层提取数据的时间序列特征,其卷积运算可识别数据中的局部特征和相关性。注意力层赋予不同时刻的数据不同的权重,使得模型能够关注输入数据中与输出数据最相关的部分。LSTM 层捕获复杂的长期依赖关系。最后,经过全连接层,模型输出预测值。




图 1 CNN-Attention-LSTM 模型结构

Fig. 1 CNN-Attention-LSTM model structure diagram

2 实例验证

2.1 研究区概况

研究区位于河南省西南部,地处南阳盆地,总面积为 2 360.32 km²;地貌特点为山少岗多平原广;地势西北高、东南低,自西向东呈缓慢倾斜状;属亚热带季风型大陆性气候,四季分明,受季风转换影响,夏季高温多雨,冬季温和少雨,整体温暖湿润^[28];年降水量约 723 mm,年平均气温为 15.1℃;2008 年浅层地下水储量为 2.37 亿 m³。

研究区地下水类型为松散岩类孔隙含水岩组,具体分为:①浅层含水层。主要由工作区域内的全新统、上更新统及中更新统所形成的中砂与粗砂含砾石层构成,埋藏较浅,底板埋深 50~60 m,属于潜水及半承压水,主要用途为农业灌溉。②中深层含水层则广泛分布于研究区内,主要由第四系中更新统和下更新统的冲洪积物及冲湖积物构成。其顶板埋深为 45~75 m,底板埋深为 200~350 m。中深层地下水是城市供水及地源热泵系统的主要水源,通常井深在 100~200 m 之间。研究区的地下水补给来源主要包括大气降水、地下径流和人工灌溉,其中大气降水是主要补给形式。

2.2 数据来源

结合相关文献^[21-25],基于研究区地下水动态变

化类型,选取温度、降水量、蒸发量和前期水位作为影响地下水水位变化的输入变量,所有数据均来自 2009 年河南省某市数字化城市课题。观测井数据采用 1999—2008 年的系列数据,剔除不符合的数据类目,共筛选出 17 眼观测井数据,其分布如图 1 所示。各观测井 1999—2008 年地下水水位变化呈现年度周期性特征,夏季水位较高,冬季水位较低。降水主要集中在夏季,降水量约占全年降水量的 60%。温度、蒸发量的年度变化也具有年度周期性特征,夏季值最高,冬季最低。




图 2 研究区观测井分布

Fig. 2 Distribution of observation wells in the study area

2.3 数据选取与处理

2.3.1 特征选取

研究区地处平原,地下水补充来源主要为降水。温度、降水量和蒸发量足以反映气象条件对地下水水位的影响,前期水位则反映了地下水系统的惯性。综合考虑这 4 个影响因子,有助于建立更为准确可靠的地下水水位预测模型。除了这 4 个主要影响因子外,地质条件、水文地质条件、人类活动等因素也会对研究区地下水水位产生影响。首先,鉴于本文旨在探索水位预测中的具体问题,因此选择了与研究问题关联最紧密、影响力最显著的因子;其次,更多的影响因子可能会引入更多的噪声,增加模型的复杂性,进而影响结果的稳定性;此外,还应考虑数据的可用性和数据收集的成本。获取多因素数据往往需要投入更多资源与时间,而温度、降水量、蒸发量及前期水位数据均为研究区水文气象监测网络的常规监测要素,不仅易于获取,也为模型的构建与更新提供了便利,保证了地下水水位预测的可行性和效率。

2.3.2 数据预处理

由于传感器异常以及环境因素可能导致数据缺失,需要对数据进行预处理。考虑到时间序列在间隔内的观测数据是逐渐变化的,因此选择线性插值

法来解决数据缺失问题。线性插值法是一种常用的数据预处理方法,其原理是通过连接已知数据点间的直线来估算缺失值;对于时间序列数据,该方法假设缺失值与相邻已知观测值之间呈线性变化关系。线性插值方程为

$$x_k = \frac{t_{k+1} - t_k}{t_{k+1} - t_{k-1}}x_{k-1} + \frac{t_k - t_{k-1}}{t_{k+1} - t_{k-1}}x_{k+1} \tag{2}$$

式中: x_k 、 t_k 为缺失值及其对应的日期; x_{k-1} 、 t_{k-1} 为缺失值前的相邻已知值及其对应的日期; x_{k+1} 、 t_{k+1} 为缺失值之后的相邻已知值和对应的日期。

2.3.3 数据归一化

水位预测中不同影响因子的数据范围存在差异。若直接输入原始数据而不进行进一步处理,会导致模型学习速率放缓,并产生不准确的预测结果。为减轻这种影响,需对数据进行标准化处理。采用 Max-Min 归一化方法,将所有数据转换到 0~1 的范围内:

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{3}$$

式中: x 为原始数据; x^* 为归一化后的数据; $x_{\min}$ 、 $x_{\max}$ 分别为数据集的最小值和最大值。

2.4 模型建立

2.4.1 模型训练

CNN-Attention-LSTM 模型训练过程如图 3 所示。




图 3 CNN-Attention-LSTM 模型训练过程

Fig. 3 Training process of CNN-Attention-LSTM model

- a. 数据输入:输入目标观测井的时间序列数据集。将温度、降水量、蒸发量和前期水位作为影响因素,模型输出为地下水水位。
- b. 划分数据集:研究区 1999—2008 年每个测井的地下水水位间隔 5 d 记录一次,每个月记录 6 次,共有记录 720 条。将 10 a 的地下水水位数据划分为训练集(1999—2006 年,共 576 个记录)和测试集(2007—2008 年,共 144 个记录)。
- c. 数据归一化:对地下水水位时间序列数据进行归一化,以消除不同量纲的影响。
- d. CNN 层:将归一化的地下水水位数据集输

入卷积层,卷积层会通过 1 组可训练的滤波器在时间序列数据上滑动。每个滤波器负责提取数据中特定类型的特征,经处理后输出特征图,这些特征图包含了从原始输入数据中提取的地下水水位时间序列特征。

- e. 注意力层:计算每个时间步的注意力权重(表示该时间步在预测地下水水位中的重要性)。将注意力权重与原始输入数据相乘,突出显示影响地下水水位的重要特征数据。
- f. LSTM 层:利用 LSTM 层隐藏状态对时间序列进行计算。在训练过程中,LSTM 层自动保存在验证集上具有最佳性能的最佳模型,在后续的预测中调用最优模型。
- g. 全连接层:将提取的特征进行整合并转换为适合输出的特征向量。
- h. 判断:判断模型的训练次数是否达到设定值。如果达到设定的训练次数,则模型训练结束;否则,返回步骤 d 继续训练模型。

2.4.2 特征权重

CNN-Attention-LSTM 模型作为一种深度学习方法,由于难以直观地观察和理解从输入变量到预测结果的过渡,通常被视为“黑匣子”。因此,模型训练完成,进一步量化各种影响因素对地下水水位预测的影响至关重要。SHAP (Shapley 加法解释)算法通过计算特征对结果的边际贡献 (SHAP 值),为该模型提供了一个有效的解释框架。该算法不仅评估了特征的权重,还阐明了影响因素与结果之间的交互关系,从而显著提高了模型的可解释性。

通过计算 CNN-Attention-LSTM 模型中各种影响因素的 SHAP 值,可以直观地观察到每个特征对地下水水位预测的影响程度。SHAP 值的范围从 -1 到 1,其中 1 表示变量之间存在强大的正相关,-1 表示变量之间存在显著的负相关关系,而 0 则表明这些变量之间不存在任何线性关系。如表 1 所示,前期水位对地下水水位预测的影响最大。

表 1 地下水水位影响因素 SHAP 值

地下水水位影响因素	SHAP 值
温度	0.22
蒸发量	0.22
降水量	0.35
前期水位	0.61

2.4.3 模型预测

对训练完成后的 CNN-Attention-LSTM 模型执行预测任务,预测过程如下:

- a. 加载最优模型。加载训练过程中保存的最

优模型。

b. 最优模型预测。利用训练过程中保存的最优模型对测试集数据进行预测。

c. 数据反归一化。对预测数据进行反归一化操作后输出。

d. 计算评价指标。根据输出的预测值与实测值,计算平均绝对误差(MAE)、均方根误差(RMSE)和决定系数(R^2)。

e. 输出结果。输出预测值及评价指标计算结果。

2.4.4 模型参数敏感性分布

a. 卷积层。卷积核数和大小对模型性能的影响值得关注。①卷积核数决定了特征图的数量,若数量过多,可能造成特征提取冗余,增加了计算的复杂度并提升了过拟合风险;数量过少则无法充分捕捉数据特征,易导致模型欠拟合。②卷积核大小会影响模型局部特征的捕捉能力;过大的卷积核容易捕捉到全局信息而忽视局部细节,同时增加了计算量;较小的卷积核更能捕捉局部细节,却可能忽视全局信息。

b. 池化层。其主要作用是降采样以减少特征图尺寸。当设置参数池化窗口大小为 1 时,系统不进行池化操作,保持特征图原始尺寸,虽然能保留更多信息,但会增加计算量;反之,执行池化操作可显著降低计算量,但可能会损失部分特征信息。

c. LSTM 层。①神经元数。影响对时序特征的捕捉能力,数量过多会导致过拟合,同时增加计算复杂度,过少则可能无法充分捕捉时序依赖关系。②时间步长。决定了 LSTM 处理的序列长度,步长过长可能引发梯度消失或爆炸,同时增加计算量;而过短则可能难以捕捉长期依赖关系。③学习率。控制优化器更新权重的步长,学习率过大可能导致训练不稳定甚至发散,过小则可能使训练进程过慢,且易陷入局部最优。④批量大小。决定了每次权重更新时使用的样本数量。批量过大可能增加内存消耗,但可以提高训练稳定性;过小则可能导致训练不稳定,但有助于跳出局部最优。

参考田辽西等^[17,24]深度神经网络结构参数选取方法,并经过反复验算测试后调整模型参数,最终得到 CNN-Attention-LSTM 模型参数,如表 2 所示。CNN 卷积层采用宽卷积核,以获得较大的感受野,从而提取更多的特征信息并有效抑制噪声干扰;池化层采用最大池化方式,保留核心特征信息,同时对边界部分进行全 0 填充,保证输出尺寸不发生变化;LSTM 层采用 Adam 优化算法优化交叉熵损失函数,以提高计算效率,缩短训练时间;CNN 卷积层和 LSTM 层都采用 ReLU 激活函数。

表 2 CNN-Attention-LSTM 参数设置

Table 2 CNN-Attention-LSTM Parameters

层名称	模型参数	取值
卷积层	滤波器数	64
	卷积核大小	5
	池化窗口大小	1
池化层	池化核大小	2
	步长	2
	单元数	64
LSTM 层	时间步长	36
	学习率	0.001
	批量大小	32
	训练轮数	200

CNN-Attention-LSTM 模型包含大量超参数,这些参数的设计与选择对模型的最终性能有着显著影响。采用网格搜索方法对时间步长、学习率和批量大小进行客观且系统的优化。网格搜索会在预设的参数搜索空间中构建网格,在每个网格点上训练并评估模型性能,最终通过比较模型在不同网格点上的性能,确定最优的参数设置。时间步长分别选择 18、36、54、72,学习率分别选择 0.005、0.002、0.001、0.01,批量大小分别选择 16、32、64、128。通过网格搜索,对这些组合进行交叉验证,以评估性能。最后得出时间步长为 36、批量大小为 32、学习率为 0.001 时计算结果最优的结论。

2.5 模拟结果对比分析

2.5.1 评价指标

采用平均绝对误差、均方根误差和决定系数来评估模型的性能。

a. 平均绝对误差是最直接量化平均误差大小的方法。

b. 均方根误差对异常值敏感,因此用来描述异常值的存在。

c. 决定系数取值范围为[0,1],结果越接近 0,表明模型拟合效果越差;结果越接近 1,模型拟合效果越好。

2.5.2 模型预测结果对比

对 17 眼观测井地下水水位分别进行预测,预测结果如表 3 所示。预测结果表明,所有观测井决定系数均大于 0.9,且 10 眼观测井大于 0.97;5 眼观测井的均方根误差大于 0.1;5 眼观测井的平均绝对误差大于 0.1。总体来说,均方根误差和平均绝对误差较低。

为了保证模型的优越性,选取预测结果 R^2 最小值(1 号井)、中间值(6 号井)、最大值(14 号井)对 LSTM、CNN、Attention-LSTM、CNN-LSTM 模型开展对比试验,选择与 CNN-Attention-LSTM 模型相同的参数。不同预测方法的预测结果如表 4 所示,预测结

表 3 不同观测井预测结果

Table 3 Prediction results of different wells			
观测井号	MAE	RMSE	R^2
1	0.052	0.059	0.951
2	0.053	0.061	0.989
3	0.047	0.054	0.957
4	0.136	0.162	0.970
5	0.051	0.058	0.977
6	0.144	0.167	0.971
7	0.055	0.062	0.989
8	0.151	0.153	0.955
9	0.043	0.050	0.971
10	0.052	0.058	0.991
11	0.028	0.033	0.980
12	0.051	0.058	0.964
13	0.048	0.056	0.975
14	0.054	0.061	0.992
15	0.121	0.104	0.977
16	0.053	0.061	0.957
17	0.153	0.156	0.953

表 4 不同模型预测结果对比

Table 4 Comparison of prediction results of different models				
观测井号	预测模型	MAE	RMSE	R^2
1	CNN-Attention-LSTM	0.051	0.058	0.951
	Attention-LSTM	0.055	0.069	0.931
	CNN-LSTM	0.063	0.075	0.918
	LSTM	0.084	0.101	0.851
	CNN	0.303	0.230	0.727
6	CNN-Attention-LSTM	0.144	0.167	0.971
	Attention-LSTM	0.215	0.228	0.945
	CNN-LSTM	0.257	0.261	0.928
	LSTM	0.312	0.339	0.893
	CNN	0.309	0.235	0.741
14	CNN-Attention-LSTM	0.053 5	0.061	0.992
	Attention-LSTM	0.155	0.198	0.923
	CNN-LSTM	0.363	0.355	0.891
	LSTM	0.441	0.518	0.842
	CNN	0.413	0.638	0.732




图 4 模型预测结果对比

Fig. 4 Comparison of results of prediction models

果对比见图 4。

由表 4 和图 4 分析可知,5 种模型的预测性能优劣排序依次为 CNN-Attention-LSTM、Attention-LSTM、CNN-LSTM、LSTM、CNN 模型。CNN 具有强大的局部特征提取能力,但对于长期依赖关系的学习能力有限。其预测值与实测值之间的差异较大,且波动与真实值相比相对平缓,表明 CNN 难以捕捉地下水水位变化的长期趋势。LSTM 擅长分析长期依赖关系,能够在一定程度上刻画地下水水位变化的趋势。与 CNN 相比,LSTM 的预测性能有所提升,即 LSTM 更适合处理具有长期依赖关系的时间序列数据。CNN-LSTM 融合了 CNN 和 LSTM 的优势,充分利用了 CNN 的局部特征提取能力和 LSTM 的全局特征捕捉能力。与单独的 CNN 和 LSTM 相比,CNN-LSTM 模型的预测误差更小。Attention-LSTM 在 LSTM 模型的基础上引入了 Attention 机制,能够重点关注影响预测结果的重要特征。注意力机制的加入进一步提高了预测精度,但模型在峰值预测方面仍有提升空间,预测值可能高于实测值。CNN-Attention-LSTM 模型将 CNN、Attention 机制和 LSTM 的优势有机结合,在预测地下水水位变化方面表现出卓越的性能。该模型能够有效捕捉时间序列数据的局部和全局特征,并重点关注影响预测结果的关键信息。具体而言,CNN 提取空间特征,识别影响地下水水位变化的模式和趋势;注意力机制分配权重,突出与预测相关的关键时间步长或特征;LSTM 学习长程依赖关系,捕捉地下水水位变化的动态演化过程。通过综合利用这 3 种模型的优势,CNN-Attention-LSTM 模型能够全面解析地下水水位变化的复杂规律,进而实现更精准、更稳健的预测。

为了进一步量化地下水水位预测精度并比较不同模型预测结果的准确性与稳定性,绘制 1 号井、6 号井和 14 号井 5 种模型的预测残差箱型图,见图 5。可见,CNN-Attention-LSTM 模型的残差表现




图 5 预测残差箱型图

Fig. 5 Residual box plot for prediction

出较强的集中性,大多数均匀分布在 0 的两侧,且残差绝对值的最小值最小,中值与零值的接近程度较高,优于其他模型。该结果表明,CNN-Attention-LSTM 模型能够有效地捕捉地下水水位影响因子中的关键信息,显著提高预测的精度和效率。

3 结 论

a. CNN-Attention-LSTM 模型平均绝对误差为 0.074,均方根误差为 0.083,决定系数为 0.972。与对照的 4 种模型相比预测精度高,稳定性好。

b. CNN-Attention-LSTM 模型适用于具有多变量时序数据的地下水水位预测场景,能够捕捉非线性关系并进行长期预测。CNN、注意力机制、LSTM 相结合,发挥各自优势,弥补了单一模型的局限性,有效提升了地下水水位预测的准确性和稳定性,误差显著降低。

c. CNN-Attention-LSTM 模型仍存在一些局限性,如算法的预测精度依赖于训练数据的质量和数量;模型相对复杂,需要较大的计算资源和较长的训练时间;在不同地区或气候条件下可能需要进行重新训练或调整,需提高泛化能力。未来可进一步优化算法模型,探索更高效的地下水水位预测算法模型,如 CNN 擅长处理空间信息,可尝试建立地下水水位预测的时空混合模型。

参考文献:

[1] 许畅畅,温瑶,成思,等.长江口滨岸浅层地下水化学组分时空分布特征及影响机制[J].水资源保护,2022,38(3):181-188. (XU Changchang, WEN Yao, CHENG Si, et al. Spatio-temporal distribution characteristics and mechanisms of chemical composition of shallow groundwater in coastal area of Yangtze River Estuary[J]. Water Resources Protection, 2022, 38(3): 181-188. (in Chinese))

[2] 陈舟,王锦国,张延杰,等.水利水电工程地下水环境影响评价关键问题及案例分析[J].河海大学学报(自然科学版),2023,51(3):48-55. (CHEN Zhou, WANG Jinguo, ZHANG Yanjie, et al. Key issues and case analysis of groundwater environmental impact assessment in water conservancy and hydropower projects[J]. Journal of Hohai University (Natural Science), 2023, 51(3): 48-55. (in Chinese))

[3] 张婧,马贵宏,高雅,等.华北山前平原典型井灌区地下水水位变化影响因素分析[J].河海大学学报(自然科学版),2022,50(1):21-28. (ZHANG Jing, MA Guihong, GAO Ya, et al. Analysis of influencing factors of groundwater level change in typical well irrigation areas in North China[J]. Journal of Hohai University (Natural Science), 2022, 50(1): 21-28. (in Chinese))

[4] 吕海峰,涂井先,林泓全,等.基于 CNN-LSTM-Attention 和自回归的混合水位预测模型(英文)[J].水利水电技术(中英文),2024,55(6):16-31. (LYU Haifeng, TU Jingxian, LIN Hongquan, et al. A hybrid water level forecasting model based on CNN-LSTM-Attention with autoregressive [J]. Water Resources and Hydropower Technology, 2024, 55(6): 16-31. (in Chinese))

[5] 宁阁,苏冬阳,高春杰,等.超采区浅层地下水数值模拟及预测分析[J].中国水利水电科学研究院学报(中英文),2024,22(3):283-297. (NING Ge, SU Dongyang, GAO Chunjie, et al. Numerical simulation and prediction analysis of shallow groundwater in over exploitation area [J]. Journal of China Institute of Water Resources and Hydropower Research, 2024, 22(3): 283-297. (in Chinese))

[6] YANG Dawen, HERATH S, MUSIAKE K. A hillslope-based hydrological model using catchment area and width functions[J]. Hydrological Sciences Journal, 2002, 47(1):49-65.

[7] 冯忠伦,曹滨,王维,等.南水北调输水梁济运河区地下水水位预测[J].中国农村水利水电,2017(3):131-135.

- (FENG Zhonglun, CAO Bin, WANG Wei, et al. Groundwater table prediction of the South-to-North Water Transfer Project in the Liangji canal zone [J]. China Rural Water and Hydropower, 2017 (3): 131-135. (in Chinese))
- [8] 张嗣路,李治军,于博文,等. 五种地下水埋深预测模型对比分析:以肇州县为例[J]. 中国农村水利水电, 2022 (10): 119-124. (ZHANG Silu, LI Zhijun, YU Bowen, et al. Comparative analysis of five groundwater depth prediction models: a case study of Zhaozhou county [J]. China Rural Water and Hydropower, 2022 (10): 119-124. (in Chinese))
- [9] 魏忠成,高薇,尹华,等. 基于回归分析方法的四平市地下水可开采量研究[J]. 水电能源科学, 2017, 35 (12): 18-21. (WEI Zhongcheng, GAO Wei, YIN Hua, et al. Research on groundwater exploitable amount based on regression analysis method in Siping City [J]. Water Resources and Power, 2017, 35 (12): 18-21. (in Chinese))
- [10] 刘紫萱,周冰玉,李志威,等. 黄河源区典型泥炭湿地地下水水位时空变化及流量过程[J]. 水利水电科技进展, 2024, 44 (3): 27-33. (LIU Zixuan, ZHOU Bingyu, LI Zhiwei, et al. Spatiotemporal change of groundwater level and discharge process in a typical peatland watershed in Source Region of Yellow River [J]. Advances in Science and Technology of Water Resources, 2024, 44 (3): 27-33. (in Chinese))
- [11] 宋子奕,鲁程鹏,吴成城,等. 2009—2019 年河西走廊地下水位时空分布及演变趋势[J]. 水资源保护, 2023, 39 (2): 160-167. (SONG Ziyi, LU Chengpeng, WU Chengcheng, et al. Spatiotemporal distribution and evolution trend of groundwater level in Hexi Corridor from 2009 to 2019 [J]. Water Resources Protection, 2023, 39 (2): 160-167. (in Chinese))
- [12] 栗现文,向东进,周金龙,等. 时间序列分析方法在干旱区地下水位动态预测中的应用[J]. 工程勘察, 2011, 39 (12): 28-32. (LI Xianwen, XIANG Dongjin, ZHOU Jinlong, et al. Application of time series analysis to predict groundwater level in arid area [J]. Geotechnical Investigation & Surveying, 2011, 39 (12): 28-32. (in Chinese))
- [13] 孙虹洁,赵振华,黄林显,等. 多变量 LSTM 神经网络模型在地下水位预测中的应用[J]. 人民黄河, 2022, 44 (8): 69-75. (SUN Hongjie, ZHAO Zhenhua, HUANG Linxian, et al. Application of multi-variable LSTM neural network model for groundwater levels prediction [J]. Yellow River, 2022, 44 (8): 69-75. (in Chinese))
- [14] 宾零陵,蒋睿文,曹永强,等. 京津冀水资源生态足迹动态变化与预测[J]. 水资源保护, 2023, 39 (5): 32-38. (BIN Lingling, JIANG Ruiwen, CAO Yongqiang, et al. Dynamic change and prediction of ecological footprint of water resources in Beijing-Tianjin-Hebei region [J]. Water Resources Protection, 2023, 39 (5): 32-38. (in Chinese))
- [15] 牛欣怡,鲁程鹏,卢佳赟,等. 机器学习模型在地下水埋深模拟中的适应性分析[J]. 河海大学学报(自然科学版), 2022, 50 (4): 74-82. (NIU Xinyi, LU Chengpeng, LU Jiayun, et al. Adaptability analysis of machine learning model in groundwater depth simulation [J]. Journal of Hohai University (Natural Science), 2022, 50 (4): 74-82. (in Chinese))
- [16] 薛萍,张召,雷晓辉,等. 基于 BP 神经网络的不同时间尺度泵站前池水位预测模型[J]. 南水北调与水利科技 (中英文), 2022, 20 (2): 393-407. (XUE Ping, ZHANG Zhao, LEI Xiaohui, et al. Prediction model for forebay water level of pumping stations with different time scales based on BP neural networks [J]. South-to-North Water Transfer and Water Science & Technology, 2022, 20 (2): 393-407. (in Chinese))
- [17] 田辽西,覃华清. 基于多变量 LSTM 神经网络的地下水位预测方法研究[J]. 干旱区资源与环境, 2024, 38 (9): 138-146. (TIAN Liaoxi, QIN Huaqing. Research on groundwater level prediction method based on multi-variable LSTM neural network [J]. Journal of Arid Land Resources and Environment, 2024, 38 (9): 138-146. (in Chinese))
- [18] WUNSCH A, LIESCH T, BRODA S. Groundwater level forecasting with artificial neural networks: a comparison of long short-term memory (LSTM), convolutional neural networks (CNNs), and non-linear autoregressive networks with exogenous input (NARX) [J]. Hydrology and Earth System Sciences, 2021, 25 (3): 1671-1687.
- [19] WUNSCH A, LIESCH T, BRODA S. Deep learning shows declining groundwater levels in Germany until 2100 due to climate change [J]. Nature Communications, 2022, 13 (1): 1221.
- [20] 张朝逢,陈皓锐,岳中奇. 基于长短时记忆网络(LSTM)的地下水埋深模拟预测:以关中平原为例的实例分析[J]. 中国农村水利水电, 2020 (9): 127-131. (ZHANG Chaopeng, CHEN Haorui, YUE Zhongqi. Modelling groundwater table depth in Guanzhong, Shaanxi Province by long short-term memory (LSTM) based model [J]. China Rural Water and Hydropower, 2020 (9): 127-131. (in Chinese))
- [21] 闫佰忠,孙剑,王昕洲,等. 基于多变量 LSTM 神经网络的地下水位预测[J]. 吉林大学学报(地球科学版), 2020, 50 (1): 208-216. (YAN Baizhong, SUN Jian, WANG Xinzhou, et al. Multivariable LSTM neural network model for groundwater levels prediction [J]. Journal of Jilin University (Earth Science Edition), 2020, 50 (1): 208-216. (in Chinese))

microfiber pollution in the northeast USA [J]. Marine Pollution Bulletin, 2017, 124(1): 245-251.

[26] VERMAIRE J C, POMEROY C, HERCZEGH S M, et al. Microplastic abundance and distribution in the open water and sediment of the Ottawa River, Canada, and its tributaries[J]. Facets, 2017, 2(1): 301-314.

[27] MCCORMICK A, HOELLEIN T J, MASON S A, et al. Microplastic is an abundant and distinct microbial habitat in an urban river [J]. Environmental Science & Technology, 2014, 48(20): 11863-11871.

[28] MOORE C J, LATTIN G L, ZELLERS A F. Quantity and type of plastic debris flowing from two urban rivers to coastal waters and beaches of southern California [J]. Revista de Gestão Costeira Integrada-Journal of Integrated Coastal Zone Management, 2011, 11(1): 65-73.

[29] LECHNER A, KECKEIS H, LUMESBERGER-LOISL F, et al. The Danube so colourful: a potpourri of plastic litter out-numbers fish larvae in Europe's second largest river [J]. Environmental Pollution, 2014, 188: 177-181.

[30] CARPENTER E J, ANDERSON S J, HARVEY G R, et al. Polystyrene spherules in coastal waters[J]. Science, 1972, 406(772): 749-750.

[31] 徐沛, 彭谷雨, 朱礼鑫, 等. 长江口微塑料时空分布及风险评估[J]. 中国环境科学, 2019, 39(5): 2071-2077. (XU Pei, PENG Guyu, ZHU Lixin, et al. Spatial-temporal distribution and pollution load of microplastics in the Changjiang Estuary [J]. China Environmental Science, 2019, 39(5): 2071-2077. (in Chinese))

[32] 侯俊, 许晓雅, 程芳, 等. 微塑料与有机污染物的相互作用及环境行为研究进展[J]. 河海大学学报(自然科学版), 2020, 48(1): 22-28. (HOU Jun, XU Xiaoya, CHENG Fang, et al. Research progress on interaction and environment behavior between microplastics and organic pollutants [J]. Journal of Hohai University (Natural Sciences), 2020, 48(1): 22-28. (in Chinese))

[33] TOMLINSON D L, WILSON J G, HARRIS C R, et al. Problems in the assessment of heavy-metal levels in estuaries and the formation of a pollution index [J]. Helgoländer Meeresuntersuchungen, 1980, 33: 566-575.

[34] EVERAERT G, VAN CAUWENBERGHE L, RIJCKE M D, et al. Risk assessment of microplastics in the ocean: modelling approach and first conclusions [J]. Environmental Pollution, 2018, 242: 1930-1938.

(收稿日期: 2024-11-28 编辑: 胡新宇)

(上接第 235 页)

[22] 侯金霄, 黄林显, 胡晓农, 等. 基于 EMD-LSTM 耦合模型的趵突泉岩溶地下水水位预测应用[J]. 水资源与水工程学报, 2023, 34(4): 92-98. (HOU Jinxiao, HUANG Linxian, HU Xiaonong, et al. Application of EMD-LSTM coupled model to karst groundwater level prediction in Baotou Spring[J]. Journal of Water Resources and Water Engineering, 2023, 34(4): 92-98. (in Chinese))

[23] PAN Mingyang, ZHOU Hainan, CAO Jiayi, et al. Water level prediction model based on GRU and CNN[J]. IEEE Access, 2020, 8: 60090-60100.

[24] 冯鹏宇, 金韬, 沈一选, 等. 基于 CNN-Transformer 的城区地下水位预测[J]. 计算机仿真, 2023, 40(4): 492-498. (FENG Pengyu, JIN Tao, SHEN Yixuan, et al. Prediction of urban groundwater level based on CNN-Transformer[J]. Computer Simulation, 2023, 40(4): 492-498. (in Chinese))

[25] WEI Aihua, LI Xue, YAN Liangdong, et al. Machine learning models combined with wavelet transform and phase space reconstruction for groundwater level forecasting[J]. Computers and Geosciences, 2023, 177: 105386.

[26] 佃松宜, 厉潇滢, 杨丹, 等. 基于融合注意力机制 LSTM 网络的地下水位自适应鲁棒预测[J]. 工程科学与技术, 2024, 56(1): 54-64. (DIAN Songyi, LI Xiaoying, YANG Dan, et al. Adaptive robust prediction of groundwater level based on fusion attention mechanism LSTM network[J]. Advanced Engineering Sciences, 2024, 56(1): 54-64. (in Chinese))

[27] 任欢, 王旭光. 注意力机制综述[J]. 计算机应用, 2021, 41(增刊1): 1-6. (REN Huan, WANG Xuguang. Review of attention mechanism [J]. Journal of Computer Applications, 2021, 41(Sup1): 1-6. (in Chinese))

[28] 李小根, 段小芳, 付景保, 等. 基于 GIS 的丹江口水库土地利用/覆被动态变化特征分析[J]. 华北水利水电大学学报(自然科学版), 2022, 43(3): 90-98. (LI Xiaogen, DUAN Xiaofang, FU Jingbao, et al. Analysis of land use and land cover dynamic change characteristics of Danjiangkou Reservoir based on GIS[J]. Journal of North China University of Water Resources and Electric Power (Natural Science Edition), 2022, 43(3): 90-98. (in Chinese))

(收稿日期: 2024-11-21 编辑: 胡新宇)