

融合长短时记忆与图结构学习的水库水位预测

郭宝椿¹, 李佐勇^{2,3}, 陈健¹, 卢维楷¹, 马森标⁴

(1. 福建理工大学 电子电气与物理学院, 福建 福州 350118;

2. 闽江学院 计算机与控制工程学院, 福建 福州 350108;

3. 福建省信息处理与智能控制重点实验室, 福建 福州 350121;

4. 福建中锐网络股份有限公司, 福建 福州 350108)

摘要: 水库水位变化受降雨、泄洪、蒸发等众多因素影响, 现有水库水位预测方法的预测精度有待提升。为此, 提出一种融合长短期记忆网络(long short-term memory, LSTM)和图卷积神经网络(graph convolution neural network, GCN)的水库水位预测模型。该模型首先借助 LSTM 提取水位与相关影响因素的时序依赖特征; 随后, 设计图结构学习模块, 自动捕捉水位及不同影响因素间的关联关系; 最后利用 GCN 进行表征学习和预测。在三峡大坝数据集及合作企业提供的数据集上开展了广泛实验, 实验结果证实了所提模型的有效性和优越性。

关键词: 水库水位预测; 长短期记忆网络; 图神经网络; 深度学习

中图分类号: TP389.1

文献标志码: A

文章编号: 2097-3853(2024)01-0090-05

Reservoir level prediction via integrating long short-term memory and graph structure learning

GUO Baochun¹, LI Zuoyong^{2,3}, CHEN Jian¹, LU Weikai¹, MA Senbiao⁴

(1. School of Electronic, Electrical and Physics, Fujian University of Technology, Fuzhou 350118, China;

2. School of Computer and Control Engineering, Minjiang University, Fuzhou 350108, China;

3. Fujian Provincial Key Laboratory of Information Processing and Intelligent Control, Fuzhou 350121, China;

4. Fujian Zhongrui Network Co., Ltd., Fuzhou 350108, China)

Abstract: The water level change of reservoirs is affected by many factors such as rainfall, flood discharge, and evaporation. The prediction accuracy of existing reservoir water level prediction methods needs to be improved. Therefore, a reservoir water level prediction model was proposed integrating long short-term memory (LSTM) and graph convolution neural network (GCN). The proposed model first extracts time-series dependent features of water level and related influencing factors by using LSTM. Then, a graph structure learning module is designed to automatically capture the correlation between water level and different influencing factors. Finally, GCN is used for feature learning and prediction. Extensive experiments were conducted on the Three Gorges Dam dataset and datasets provided by cooperative enterprises. The experimental results demonstrated the effectiveness and superiority of the proposed model.

Keywords: reservoir level prediction; long short-term memory network; graph neural network; deep learning

水库在干旱或洪涝灾害中能保障人类生产及生命的安全, 准确预测水库水位波动对水资源的科学合理利用具有重要的意义^[1-2]。构建有效水位预测模型的关键在于捕获水位过去的变化趋势

以及其它因素对水位的影响。而外部因素对水位的影响是动态变化且复杂的, 在多雨季节, 入库流量、降雨量和出库流量都是影响水位的重要因素; 在干旱季节, 为增加蓄水, 出库流量则对水位无影

收稿日期: 2023-09-07

基金项目: 国家自然科学基金(61972187); 福建省自然科学基金(2022J01952, 2023J01953)

第一作者简介: 郭宝椿(1996—), 男, 福建龙岩人, 硕士研究生, 研究方向: 时序预测。

通信作者: 李佐勇(1980—), 男, 重庆人, 教授, 博士, 研究方向: 图像处理、模式识别、深度学习。

响;此外,在洪涝情况下,人为干预的泄洪影响也不可忽视。因此,如何有效建模多因素对水库水位的影响是水位预测中至关重要的问题。

现有对水位的预测方式大致可分为物理模型和数据驱动模型。物理模型以现实的水文循环或物理规律为基础,利用地质学及数学公式推演水位。如李捷等^[3]结合圣维南方程组的连续方程与运动方程,提出了逐时段河道流量推算的方法。然而,实际应用中地理数据及特殊水文数据常常难以获得。随着数据增多,数据驱动模型也有许多应用。Üneş 等^[4]使用模糊推理系统、支持向量机、径向基神经网络和广义回归神经网络预测大坝水位,对比结果表明,模糊推理系统虽然效果更好,但仅使用水库水位的历史数据,忽略了其它因素的影响。刘晓阳等^[5]则考虑到入库流量和出库流量对水库水位的影响,构建了小时尺度的三峡坝前水位预测模型,但受限于机器学习浅层模型的学习能力,捕获时序中复杂的内在模式仍不足。深度学习因其更为强大的特征学习能力也被引进该领域的研究中,如纪国良等^[6]使用融合长短期记忆网络(long short-term memory, LSTM)从三峡水库运行的历史数据中学习,利用当前时

刻与过去时刻的信息交互有效捕获水库数据中的变化特征;Park 等^[7]则使用比 LSTM 结构更简单、参数更少的门控循环单元(gate recurrent unit, GRU)模型预测韩国汉江水位,预测精度有效提高;Ibañez 等^[8]提出的 DNN-M 将两个 LSTM 分别作为编码器和解码器,并嵌入时间信息,在多个场景预测中均显示出较佳的性能。

上述方法在研究中更关注序列中的时间信息,对多个变量在局部时间节点对水库水位的复杂影响没有综合考虑,预测的精度还有待提高。另因不同时段中不同因素对水库水位的影响特征可以形成结构图,图卷积网络可作为挖掘不同因素之间复杂影响的工具,并可能获得更好的预测效果。因此,鉴于数据驱动方法的多种优势,本研究提出融合 LSTM 和 GCN 的方法,旨在解决单一循环神经网络对多变量建模不足的问题,为水库水位预测提供一种新颖有效的解决方案。

1 模型构建

本研究构建的融合 LSTM 与 GCN 的数据驱动水库水位预测模型的整体结构如图 1 所示。

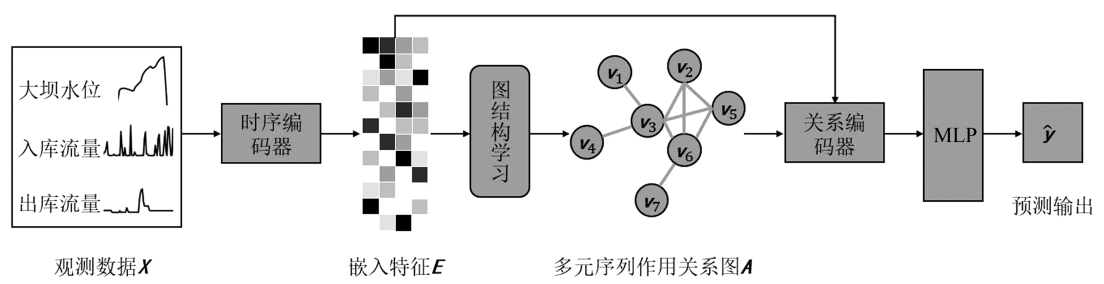


图 1 LSTM-GCN 模型
Fig.1 LSTM-GCN model

1.1 问题定义

水库水位预测实质为多变量时序预测问题,本研究记录有大坝水位、入库流量、出库流量 3 个变量的时间序列,定义为 $\text{data} = \{x_1^i, x_2^i, \dots, x_n^i\}$, 其中 $i = \{1, 2, 3\}$, 代表不同特征序列, n 为记录的时间天数。实际应用通常以固定的时间序列数据预测未来水位,因此令历史观测天数为 d , 则问题定义为给定历史观测数据 $X = \{x_1^i, x_2^i, \dots, x_d^i\} (d < n, X \in \text{data})$, 预测水库未来 1 d 的水位 \hat{X} 。

1.2 时序编码器

水位预测中,从历史数据提取时序依赖特征

是一个至关重要的环节,使用 LSTM 作为时序编码器对输入数据编排,提取序列数据中的时序特性,得到嵌入特征 E 。值得注意的是,若采用常规方式对整个序列进行编码,多个变量将被编码入同一个特征表示中,不利于后续对变量间关系的抽取。因此,本研究将每个样本中的每个变量单独作为时序编码器的输入,从而使时序依赖只在单个变量中提取。

1.3 图结构学习

水库水位预测中不同变量之间的作用关系是复杂的,且在不同地理因素、气候等影响下而具有

特异性,难以人为进行定义。受 Li 等人^[9]的启发,本研究引入图结构学习模块使得神经网络能自动学习多变量间的关系,在端到端优化中,模型会学习最有利于预测的关系。首先,在时序编码器模块中提取出嵌入特征 \mathbf{E} 后将各变量的特征展平形成 1 维的张量,随后使用多层感知机 (multi layer perceptron, MLP) 与非线性函数学习特征内的作用关系,从而能表示节点间的联系;其次,将张量与其自身的转置相乘形成矩阵再正则化;最后,用 Top- k 函数排序机制选择节点的前 k 个最近邻,用以生成多元序列作用关系图 (即邻接矩阵 \mathbf{A}),为 GCN 深入挖掘不同因素之间的深层作用关系提供保障。其多元序列作用关系图生成的伪代码如算法 1 所示。

算法 1:多元序列作用关系图生成算法

输入:嵌入特征 \mathbf{E}

输出:多元序列作用关系图 \mathbf{A} (即邻接矩阵 \mathbf{A})

(1) $\mathbf{V} = \text{Flatten}(\mathbf{E})$ // 将嵌入特征展平得到张量 \mathbf{V}

(2) $\bar{\mathbf{V}} \leftarrow \text{Relu}(\text{MLP}(\mathbf{V}))$ // 使用非线性函数学习特征的内部联系得到张量 $\bar{\mathbf{V}}$

(3) $\mathbf{K} = \text{Matmul}(\bar{\mathbf{V}} \cdot \bar{\mathbf{V}}^T)$ // 使用 Matmul 函数计算出一个矩阵

(4) $\mathbf{K}_{\text{norm}} = \text{Normalization}(\mathbf{K})$ // 对矩阵 \mathbf{K} 进行归一化操作

(5) $\mathbf{A} = \text{Top-}k\{\mathbf{K}_{\text{norm}}\}$ // 根据 Top- k 排序机制选择前 k 个最近邻生成多元序列作用关系图

1.4 关系编码器

图卷积网络是一种用于处理图结构数据的深度学习模型。关系编码器以图结构学习生成的邻接矩阵和嵌入特征作为输入,使用图卷积网络充当关系编码器挖掘节点间的深层作用。执行过程如下:

$$\mathbf{H}^{l+1} = \sigma(\hat{\mathbf{D}}^{-\frac{1}{2}} \mathbf{A} \hat{\mathbf{D}}^{-\frac{1}{2}} \mathbf{H}^l \mathbf{W}^l), (1 \leq l \leq L) \quad (1)$$

$$\hat{\mathbf{D}}_{ii} = \sum_j \mathbf{A}_{ij} \quad (2)$$

式(1)中, \mathbf{H}^l 为各个节点的特征集合,初始输入 \mathbf{H}^1 为嵌入特征 \mathbf{E} ; \mathbf{A} 为图结构的邻接矩阵,由图结构学习得到;式(2)中, $\hat{\mathbf{D}}$ 表示矩阵 \mathbf{A} 的度矩阵,其对角线上的元素表示每个节点的度数 (即与该节点相连的边的数量),第 i 个度数由对应 i 行的 j 列值求和得出; \mathbf{W}^l 为第 l 层的权重参数, σ

为非线性激活函数。

1.5 预测输出

获得关系编码器挖掘的深层特征 \mathbf{H}^L 后,将每个样本中的多个变量特征表示进行拼接,并将其表示为 $\tilde{\mathbf{H}}^L$ 。最后通过多层感知机输出预测水位,其过程如式(3)所示:

$$\hat{y} = \sigma(\omega \tilde{\mathbf{H}}^L + b) \quad (3)$$

其中, ω 为多层感知机的权重参数, b 为偏置向量, \hat{y} 为预测水位。

2 数据及其处理

以三峡大坝数据集为研究对象,所在流域地处四川盆地与长江中下游平原的结合部,其特殊位置有着独特气候变化,库区为亚热带湿润季风气候,表现为冬季短夏季长,降雨丰沛但季节分配不均^[10]。该数据集以日为时间单位,记录观测日期、大坝上游水位、大坝下游水位、大坝进水量、大坝出水量 5 个内容,选定完整且无缺失时间段记录数据 (从 2018 年 5 月 1 日至 2021 年 1 月 31 日),通过大坝下游水位、大坝进水量、大坝出水量对大坝下游水位进行预测。为使数据便于模型使用同时避免误差或量纲差异带来影响,通过滑动窗口法对数据切分形成数据集,再按 7:3 划分为训练集和测试集 (本研究所提出的模型及所有对比模型均在此训练集和测试集上进行实验)。

首先,对数据进行归一化处理,使其量纲统一,更适合模型学习,归一化方法如式(4)所示:

$$x' = \frac{x_j^i - x_{\min}^i}{x_{\max}^i - x_{\min}^i}, (i = \{1, 2, 3\}, 1 \leq j \leq n) \quad (4)$$

其中, x_j^i 为 data 中的原始数据值, x_{\min}^i 为原始数据中第 i 列的最小值, x_{\max}^i 为原始数据中第 i 列的最大值, x' 为归一化后的数据。

然后,进行模型输入、输出处理。对归一化后的数据处理成模型输入输出的需求大小,根据问题定义,模型输入为 $\mathbf{X} = \{x_1^i, x_2^i, \dots, x_d^i\}$,通过窗口滑动的方法,从数据 data (即 3 个特征序列) 的起始时间点开始,以长度为 d 的窗口作为采样片段,每次移动一个时间单位,直至数据序列末尾。

形成的模型输入集合: $\mathbf{X}_{\text{in}} = [\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_{n-d}]$ 。同理按照问题定义,选择大坝水位 y 序列采样,形成的模型输出集合: $\mathbf{Y}_{\text{out}} = [y_{d+1}, y_{d+2}, \dots, y_n]$ 。

3 实验结果分析

3.1 模型评价指标

为了评价模型有效性,以均方误差 (MSE)、平均绝对误差 (MAE)、平均绝对百分比误差 (MAPE) 作为模型的评价标准。3 个指标中, MSE 对离群值更敏感,能捕捉预测偏离情况, MAE 对于异常值的鲁棒性更强, MAPE 则可以帮助评估模型在不同数据点上的预测能力。3 个评价标准的值越小,则表示其预测效果越好。如式(5)(6)(7)所示,其中 \hat{y}_i 为预测值, y_i 为真实值(观测值)。

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2$$

(5)

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

(6)

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right|$$

(7)

3.2 实验设定及表现

使用训练集数据训练好模型后,用测试集数据对模型进行验证比较。选择 LSTM 模型作为基线, RNN、GRU、DNN-M 及经典时序预测算法 LSTNet^[11]作为参考对比,各模型在测试集上的评价指标如表 1 所示,各模型参数见表 2。

表 1 各模型在三峡大坝数据集的不同评价指标对比
Tab.1 Comparison of different evaluation indexes for each model on the Three Gorges Dam dataset

模型	MSE	MAE	MAPE
RNN	0.220 5	0.347 4	0.517 2
LSTM	0.219 2	0.350 4	0.521 0
GRU	0.208 5	0.337 3	0.502 5
LSTNet	0.215 2	0.335 4	0.499 8
DNN-M	0.216 9	0.351 6	0.524 3
LSTM-GCN	0.201 0	0.331 2	0.494 1

由表 1 可知,6 种预测模型均能对三峡大坝水位实现较为准确的预测,但是相对于以循环神经网络为核心的 LSTM、GRU、DNN-M 模型以及时序预测模型 LSTNet,所提出的 LSTM-GCN 展现了更加优异的性能。具体而言,相较于对比方法中表现最好的 GRU, LSTM-GCN 的 MSE 降低了 3.6%、MAE 降低了 1.8%、MAPE 降低了 1.7%。值得注意的是,

与仅采用 LSTM 的方法对比,所提方法的 MSE 降低了 8.3%、MAE 降低了 5.5%、MAPE 降低了 5.2%,这表明使用图卷积网络有利于挖掘不同因素对水库水位的复杂影响,弥补了单一循环神经网络对多变量因素之间作用建模的不足。

表 2 模型参数及网络层

Tab.2 Model parameters and network layers

模型参数或网络层	数值	参数说明
RNN(1 层)	64	神经元个数
LSTM(1 层)	64	神经元个数
GRU(1 层)	64	神经元个数
GCN	10	图卷积输出维度
Dropout	0.2	神经元随机丢弃率
Adam	—	优化器
Lr	0.01	学习率
d	15	观测数据长度
Batch size	8	样本批数
Epoch	300	训练次数

为进一步验证 LSTM-GCN 模型预测效果,实验将 LSTM 与 LSTM-GCN 模型的预测结果进行可视化对比,其结果如图 2 所示。




图 2 LSTM 和 LSTM-GCN 模型三峡大坝水位预测对比
Fig.2 Comparison of LSTM and LSTM-GCN models for Three Gorges Dam water level prediction

总体而言, LSTM-GCN 的预测结果更好地拟合了真实水位,同时更好地捕捉到了突变情况,从而进一步验证了 LSTM-GCN 模型的优势。

为验证该模型在中型水库上的预测性能,使用福建省福州市某中型水库 2021 年 1 月至 11 月采集的每日水库水位、降雨和泄洪数据进行实验。所提方法与对比模型的评价指标如表 3 所示,同

样选取 LSTM 模型与本文模型进行可视化对比,如图 3 所示。

表 3 各模型在中型水库数据集的不同评价指标对比
Tab.3 Comparison of different evaluation indexes for each model on a medium-sized reservoir dataset

模型	MSE	MAE	MAPE
RNN	0.859 0	0.680 5	0.632 6
LSTM	0.740 6	0.538 9	0.495 8
GRU	0.698 9	0.505 3	0.466 4
LSTNet	0.736 4	0.541 3	0.497 2
DNN-M	0.693 7	0.543 2	0.498 0
LSTM-GCN	0.602 3	0.498 0	0.458 9




图 3 LSTM 和 LSTM-GCN 模型中型水库水位预测对比
Fig.3 Comparison of LSTM and LSTM-GCN models for medium-sized reservoir water level prediction

参考文献:

[1] 安新代. 黄河小浪底水库防洪减淤作用与效益跟踪分析[J]. 人民黄河,2023,45(8):37-42.

[2] 郭生练,刘攀,王俊,等. 再论水库汛期水位动态控制的必要性和可行性[J]. 水利学报,2023,54(1):1-12.

[3] 李捷,陈俊英,苏晓,等. 基于圣维南方程组的水位流量单值关系应用[J]. 人民黄河,2016,38(1):22-27.

[4] ÜNEŞ F,DEMIRCI M,TAŞAR B,et al. Estimating dam reservoir level fluctuations using data-driven techniques[J]. Polish Journal of Environmental Studies,2019,28(5):3451-3462.

[5] 刘晓阳,姚华明,张海荣,等. 基于机器学习的三峡水库小时尺度坝前水位预测[J]. 人民长江,2023,54(2):147-151.

[6] 纪国良,周曼,刘涛,等. 基于循环神经网络的水库水位预测方法[J]. 长江科学院院报,2022,39(3):80-85.

[7] PARK K,SEONG Y,JUNG Y,et al. Development of water level prediction improvement method using multivariate time series data by GRU model[J]. Water,2023,15(3):587.

[8] IBÁÑEZ S C,DAJAC C V G,LIPONHAY M P,et al. Forecasting reservoir water levels using deep neural networks:a case study of angat dam in the Philippines[J]. Water,2021,14(1):34.

[9] LI T F,ZHAO Z B,SUN C A,et al. Domain adversarial graph convolutional network for fault diagnosis under variable working conditions[J]. IEEE Transactions on Instrumentation and Measurement,2021,70:1-10.

[10] 张静,刘增进,肖伟华,等. 三峡水库蓄水后库区气候要素变化趋势分析[J]. 人民长江,2019,50(3):113-116,165.

[11] LAI G K,CHANG W C,YANG Y M,et al. Modeling long-and short-term temporal patterns with deep neural networks[C] //SIGIR '18:The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval. New York:ACM,2018:95-104.