

杨婷婷, 虞佳颖, 肖姚, 等. 基于 Embedding-GRU 的水库水位预测模型[J]. 南水北调与水利科技(中英文), 2023, 21(5): 940-950. YANG T T, YU J Y, XIAO Y, et al. Reservoir level prediction based on Embedding-GRU model[J]. South-to-North Water Transfers and Water Science & Technology, 2023, 21(5): 940-950. (in Chinese)

基于 Embedding-GRU 的水库水位预测模型

杨婷婷¹, 虞佳颖², 肖姚³, 罗小亮⁴

(1. 河北省水文勘测研究中心, 石家庄 050031; 2. 浙江同济科技职业学院水利工程学院, 杭州 311231;
3. 重庆大学航空航天学院, 重庆 400044; 4. 余杭区水文水资源监测站, 杭州 311115)

摘要:为解决因水库数据采集设备能力有限、水文数据不全导致预测水库水位时预测精度较低的问题,以四岭水库每小时水位监测数据为例,提出基于嵌入式-门控循环单元(Embedding-gated recurrent unit, Embedding-GRU)的水库水位预测模型,即利用 Embedding 方法将单维降雨量数据升维至多维数据,扩大降雨的气候特征,结合 GRU 算法进行水库水位预测。将该模型与传统深度学习算法长短期记忆(long short-term memory, LSTM)、门控循环单元(gated recurrent unit, GRU)、双向门控循环单元(bidirectional recurrent neural network, BiGRU)这 3 种模型对比,结果显示: Embedding-GRU 模型的预测效果均优于其他传统模型,平均绝对误差 E_{MA} 和均方根误差 E_{RMS} 分别平均下降 19.6% 和 7.7%,并且在预测次日水库水位的应用场景中决定系数 R^2 能够达到 0.989 37。结果表明:该模型耦合多种算法,扩大单变量的气候特征,具有较高预测精度和泛化能力。相较传统模型,基于 Embedding-GRU 的水库水位预测模型能够对缺少温度、气压、风速、蒸发量等监测数据的水库进行可靠度较高的预测,适用水库范围更广,为水库日常运维、除险加固提供参考。

关键词:人工智能;深度学习;水位预测;嵌入式;门控循环单元

中图分类号: TV124 **文献标志码:** A **DOI:** 10.13476/j.cnki.nsbdqk.2023.0100

水库水位(reservoir water level, RWL)预测是预判水库是否面临险情威胁的关键方法。随着水文与计算机的深入交叉研究,有越来越多的学者早已采用机器学习方法进行水位预测。张研等^[1]、高学平等^[2]利用传统的相关向量机算法、BP 神经网络进行调水工程调蓄水位的预测,刘墨阳等^[3]提出基于小波的带外源输入的非线性自回归神经网络,为洪泽湖的水位预报提供一定的参考价值。

伴随研究的深入,预测能力更优秀的深度学习算法在各个领域都展现出高度实用性,目前国内外学者开始使用深度学习算法预测水位的例子不在少数。Gharehbaghi 等^[4]使用门控循环单元(gated recurrent unit, GRU)模型预测地下水位;Kidoo 等^[5]也选择 GRU 模型来提高水位预测准确性,采用多元学习方法,有效利用气象资料提高日水位的预测精度;孙虹洁等^[6]将降水量和气温、水汽压及开采

量作为输入变量,构建基于多变量长短时记忆(long short-term memory, LSTM)神经网络的地下水位预测模型;薛萍等^[7]采用 BP(back propagation)神经网络预测不同时间尺度的泵站前池水位效果较好;纪国良等^[8]使用循环神经网络也能较为准确地预测水库水位;刘艳等^[9]利用 2 个不同的 LSTM 作为解码层和编码层,相较人工神经网络 ANN(artificial neural network)模型预测效果更好,收敛速度更快。

以上学者均采用单一的人工智能模型进行水位预测,单一模型往往存在泛用性低^[4-6]的问题,为弥补上述单一人工智能模型的不足,也有学者^[10-12]采用神经网络模型耦合的方式进行水位预测^[13]的研究,其中少部分学者输入单一变量进行水位预测。因 SARIMA 模型的残差不能满足建模方法的自相关性要求,Azad 等^[14]基于前一时刻水位数据提出一种用于水库水位预测的 SARIMA-ANN 模型。Pan

收稿日期: 2023-07-31 修回日期: 2023-10-25 网络出版时间: 2023-10-26

网络出版地址: <https://link.cnki.net/urlid/13.1430.TV.20231026.1354.002>

基金项目: 国家自然科学基金项目(51408505); 浙江省水利厅科技项目(RC1954); 浙江省高校基本科研业务费资助项目(FRF20QN003)

作者简介: 杨婷婷(1994—),女,河北石家庄人,工程师,主要从事水文与水资源研究。E-mail: hbswld@126.com

通信作者: 虞佳颖(1994—),女,浙江杭州人,讲师,主要从事水文预报和水利数据智能分析研究。E-mail: yujiaying@zjtongji.edu.cn

等^[15]结合 GRU 和卷积神经网络 (convolutional neural network, CNN) 的网络结构, 构建 CNN-GRU 模型预测水位, 输入变量同样仅为水位数据, 预测评价指标分别采用 Nash-Sutcliffe 效率系数 (E_{NS})、平均相对误差 (E_{MR}) 和均方根误差 (E_{RMS}), 该模型具有更高精度。更多学者则是在耦合神经网络模型^[16-18]时输入多变量特征进行水位预测。刘晓伟等^[19]进行泵站站前水位预测时, 在 GRA-NARX (grey relation analysis nonlinear autoregressive model with exogenous inputs) 耦合模型中也输入断面水位、泵站流量等多变量。刘青松等^[20]提出一种基于自回归预测法和循环神经网络 (autoregression-recurrent neural network, AR-RNN) 的多变量水位预测模型, 改善传统单变量水文预测模型无法充分考虑众多因素的缺点, 相比于 SARIMA 模型和 BP 模型, 此模型的预测精度更高。上述研究表明采用耦合模型进行水位预测具有可行性, 并且多种模型之间优势互补, 相较之前单一模型, 预测精度均不同程度提高。

以上大多数研究均基于多变量、多特征的水文数据, 数据特征包含气温、湿度、降水、蒸发、风速等。但在实际情况中, 我国存在较多实时监测设备能力有限、采集数据不全甚至数据特征单一的水库, 无法直接采用多特征的人工智能水库水位 (RWL) 预测模型, 且该类水库在防汛调度和运行管理时同样具有水位预测需求。综合考虑各项现实因素, 本文以四岭水库的水位监测数据为例, 在仅有单一特征降雨量的情况下, 提出基于 Embedding-GRU 的水库水位耦合预测模型, 该模型弥补人工智能水库水位预测的单一模型精度不高和多特征水库水位耦合模型水文资料搜集困难等不足, 与其他已有水库水位人工智能预测模型相比, 预测精度更高, 适用水库范围更广。

1 研究区概况

1.1 水库流域概况

四岭水库位于太湖流域东苕溪水系北苕溪支流太平溪上。临安气象站位于临安市城关镇西郊外, 与四岭水库流域相距较近, 据该站 1959—2023 年观测资料统计, 台站处多年平均气温 15.8 ℃。平均相对湿度 82%, 平均风速 1.8 m/s, 实测最大风速 18.0 m/s。本流域属于北亚热带季风气候区, 流域内降水量年内变化与年际变化均较大。多年平均降

水量为 1 675 mm, 丰水年可超过 2 000 mm, 枯水年仅为 1 000 mm 左右。流域降水主要为春雨、梅雨和台风雨。其中, 形成流域大洪水的暴雨则以台风雨为主, 其次为梅雨。本流域台风期最大一日雨量 319.8 mm, 梅雨期最大一日雨量 197.4 mm。

1.2 水库基本情况

四岭水库是一座以防洪为主, 结合供水、灌溉、发电等综合利用的中型水利工程, 防洪能力为 50 年一遇, 在满足现行规范和大坝不加高的原则下, 校核洪水标准已调整为 2 000 年一遇。

2 数据及研究方法

2.1 水文数据来源

以 2018 年 1 月 1 日至 2022 年 12 月 31 日的降雨量和水库坝前水位监测数据展开研究, 数据采集频率为 1 h, 共 43 824 组水库水位和降雨数据, 见图 1。每年水位和降雨量有一定程度相似周期性, 在每年汛期来临前逐渐上升, 在汛期达到峰值, 之后又呈下降趋势。因此将降雨量作为变量预测水库水位具有科学性、合理性。数据均由余杭区水文水资源监测站进行实时收集归纳, 确保真实有效。将数据样本分为训练样本和测试样本。训练样本时间为 2018 年 1 月 1 日至 2021 年 12 月 31 日, 占数据样本 80%。测试样本时间为 2022 年 1 月 1 日至 2022 年 12 月 31 日, 占数据样本 20%。数据样本中每小时水位最大值为 77.87 m, 最小值为 56.28 m, 每小时降雨量最大值为 65.5 mm。

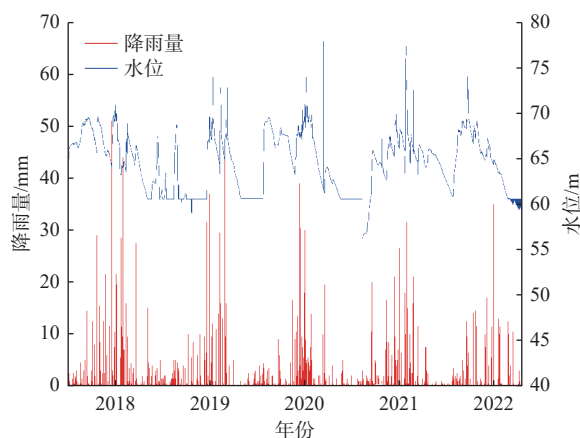


图 1 四岭水库 2018—2022 年降雨量和水位变化
Fig. 1 Changes of rainfall and water level in Siling Reservoir from 2018 to 2022

四岭水库 2018—2022 年水文变量观测值统计特征见表 1。表 1 详细说明了本研究数据的典型统计特征, 5 年内该水库每年平均水位在 64.28 m 左右,

每小时平均降雨量为 0.86 mm。从表 1 数据来看, 水位的标准差和方差在 2018 年、2019 年、2020 年、2022 年都有逐渐增大趋势, 表明水库水位预测难度

不断提高, 采用人工智能 RWL 预测混合模型有优势。后续试验阶段将对该数据进行归一化处理, 以提高预测精度。

表 1 四岭水库 2018—2022 年水文变量观测值统计特征

Tab. 1 Statistical characteristics of observed values of hydrological variables of Siling Reservoir from 2018 to 2022

水文变量	最大值	最小值	平均值	标准差	方差
2018年每小时降雨量/mm	51.00	0	0.221 62	1.461 60	2.136 52
2018年每小时水位/m	70.90	60.55	65.709 09	2.620 20	6.866 25
2019年每小时降雨量/mm	65.50	0	0.207 53	1.425 95	2.033 58
2019年每小时水位/m	73.95	58.96	62.787 29	3.089 15	9.543 95
2020年每小时降雨量/mm	39.00	0	0.207 26	1.170 92	1.371 22
2020年每小时水位/m	77.87	60.55	65.067 28	3.281 25	10.767 82
2021年每小时降雨量/mm	65.00	0	0.193 34	1.347 99	1.817 28
2021年每小时水位/m	77.33	56.28	64.345 28	3.229 00	10.427 65
2022年每小时降雨量/mm	35.00	0	0.158 38	0.988 94	0.978 11
2022年每小时水位/m	74.04	57.74	63.495 40	3.470 27	12.044 15

2.2 基于 Embedding-GRU 的水位预测模型

2.2.1 Embedding 方法

Embedding 方法最初是为解决在自然语言处理中词语 One-hot representation 的矩阵稀疏以及无法反映词与词之间的语义关系的问题, 由 Paccanaro 等^[21]提出的一种 word embedding 的词向量表示方法, 该方法能够将原来的词语稀疏向量映射到低维稠密向量, Mikolov 等^[22]则提出 word2vec 模型, 核心思想即根据词的上下文预测当前词语的概率, 当概率最大化时即得到 word embedding 词向量^[23]。随后 Embedding 方法被得到广泛应用, Wang 等^[24]在智能推荐系统中引入 Embedding 技术缓解稀疏性问题, Hui 等^[25]将用户行为 Embedding 为多维向量, 应用至推荐系统的模型训练中, 提升个性化推荐精确度。此外, Embedding 方法也成为深度学习的一种预处理阶段^[26], 本文将“降雨量”特征作为实体, 对降雨量进行 Embedding 操作, 将生成的 Embedding 特征向量作为预训练向量, 具体流程见图 2 和图 3。假设近 5 h 的降雨量规模(单位: mm)分别为 {10, 20, 40, 40, 50}, 集合的不重复元素数量为 4, 则首先转换为 One-hot representation, 生成(4, 4)的稀疏矩阵。

$$\begin{matrix} 10 \\ 20 \\ 40 \\ 50 \end{matrix} \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

图 2 One-hot 表达式

Fig. 2 One-hot representation

$$\begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} \omega_{11} & \omega_{12} \\ \omega_{21} & \omega_{22} \\ \omega_{31} & \omega_{32} \\ \omega_{41} & \omega_{42} \end{pmatrix} = \begin{pmatrix} \omega_{11} & \omega_{12} \\ \omega_{21} & \omega_{22} \\ \omega_{31} & \omega_{32} \\ \omega_{41} & \omega_{42} \end{pmatrix}$$

图 3 Embedding 举例

Fig. 3 Embedding example

若要将降雨量升维至 2 维, 则全连接层参数为 (4, 2), 对应 4 种降雨量规模的 Embedding 向量, 见图 3。每一个元素均可以用对应行的 2 维向量进行表示。因此, 若实体的不重复元素数量为 s , 需要将实体 Embedding 升维至 d 维, 则全连接层的参数矩阵为 (s, d) 。

最初的全连接层的参数矩阵可以是随机矩阵, 并不能够反映特征数据信息。因此本文将该全连接层作为第一层, 接入深度学习模型, 在训练过程中该全连接层的参数会更新, 此时降雨量对应的 Embedding 向量将会包含降雨量之间的关联信息。

2.2.2 GRU 模型

GRU 模型由 Chung 等^[27]提出, 作为 LSTM 的变体算法, 模型结构见图 4。GRU 具有两个门, 分别为更新门 z_t 和重置门 r_t 。更新门 z_t 帮助模型决定要将多少过去的信息传递到未来, 重置门 r_t 决定了有多少过去的信息需要遗忘。

GRU 神经元的前向传播由以下方程控制:

$$z_t = \sigma(W_z[h_{t-1}, x_t]) \quad (1)$$

$$r_t = \sigma(W_r[h_{t-1}, x_t]) \quad (2)$$

$$\tilde{h}_t = \tanh(W[h_t \odot h_{t-1}, x_t]) \quad (3)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (4)$$

x_t 为 t 时刻的输入, h_{t-1} 是 $t-1$ 时刻隐层的输出, z_t 由 x_t 和 h_{t-1} 通过线性变化并且相加后投入到 Sigmoid 激活函数 σ 中, 结果被压缩至 $[0,1]$, 更新门越大, 则表示记忆的信息越大。 r_t 与 z_t 表达式相同, 但是线性变换参数 W 不同。 \tilde{h}_t 为 t 时刻新的记忆信息, 使用重置门 r_t 储存过去相关的信息, r_t 先与前一时刻的输出相乘, 而 r_t 的范围同样在 $[0,1]$, 若 r_t 为 0, 则表示需要完全遗忘前一时刻的信息。 h_t 则进行了最终的记忆更新, $z_t \odot \tilde{h}_t$ 表示保留到最终记忆的信息, $(1 - z_t) \odot h_{t-1}$ 则表示保留的当前记忆, 两者相加得到最终门控循环单元输出的内容。




图4 GRU 模型结构
Fig. 4 GRU model structure




图5 降雨量 Embedding
Fig. 5 Embedding of rain fall

基于 Embedding-GRU 水库水位预测模型流程见图 6。在数据处理阶段, 首先通过 Embedding 方法对训练集降雨量数据进行升维, 获得不同降雨量的向量表达式, 然后将原始水位数据与多维降雨量数据整合, 并且经过参数测试, 选择合适的降雨量规模与 Embedding 维度作为模型参数, 获得深度学习的预训练特征向量, 接下来进行数据归一化处理, 处理公式见式(5)。其中 μ 和 σ 分别为原始数据集的均值和方差, 则归一化后数据集符合标准正态分布, 统一不同特征的度量单位, 提升模型预测精度。

$$x^* = \frac{x - \mu}{\sigma} \quad (5)$$

最后将新数据集拆分为训练集与测试集进行模型的训练与验证。

相比 LSTM 的遗忘门、输入门、输出门, GRU 神经网络仅有两个门, 并且去除单元状态, 使用隐藏状态来传输信息, 因此 GRU 神经网络具有更简单的结构、更少的训练参数、更快的训练速度, GRU 在很多应用场景下均可替代 LSTM, 作为轻量化解决方案。

2.2.3 基于 Embedding-GRU 的水位预测模型构建

基于 Embedding-GRU 的水位预测模型目的是弥补当前监测数据的局限性。四岭水库采集到的降雨量(rain fall)数据均为 $0.5n$ mm, n 为整数, 例如 $\{0.5, 0, 1.5, 0.5, \dots, 2.5, 5.0\}$, 与真实数据存在差异。根据经验, 降雨量往往比较集中在一年中的某段时间, 因此降雨量之间存在能够反映气候特征的映射。为放大在单维数据中的特征, 通过 Embedding 方法, 对降雨量数据进行升维, 放大降雨量之间的“气候”特征, 并通过试验确定较优的降雨量规模与特征维度。以图 5 降雨量 Embedding 为例, 对于单维降雨量数据, 利用采集数据作为训练样本, 根据时间顺序进行 Embedding, 最终得到降雨量的多维稠密向量。

3 试验过程与分析

3.1 评价指标

在评价各个模型预测结果的准确度时, 采用平均绝对误差^[25-27](mean absolute error, E_{MA}), 均方根误差^[27-29](root mean square error, E_{RMS})和决定系数(R^2)^[29]来进行模型的优劣判断。 E_{MA} 表示预测值和实际值之间绝对误差的平均值。 E_{RMS} 表示预测值和实际值之间差异的样本标准差。以上两种指标越小表示预测效果越好。 R^2 表示预测值与实际值的拟合程度, 该指标越接近 1 表明预测效果越好。

$$E_{MA} = \frac{1}{m} \sum_{i=1}^m |y_i - y'_i| \quad (6)$$

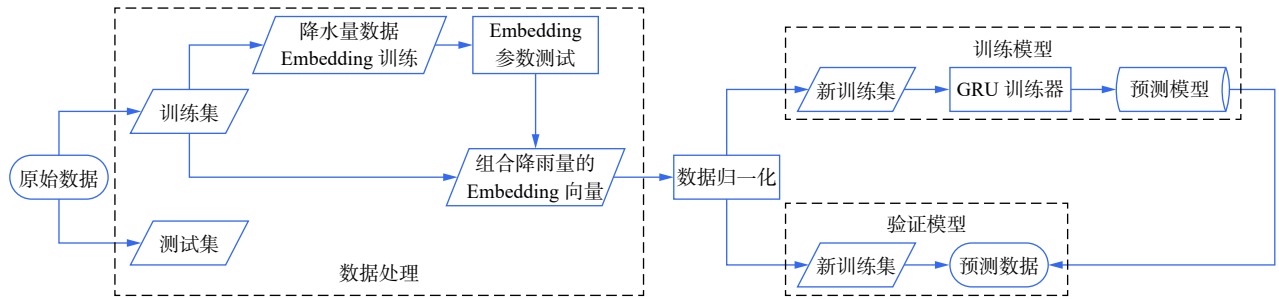


图 6 模型流程

Fig. 6 Flow chart of model

$$E_{RMS} = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - y'_i)^2} \quad (7)$$

$$R^2 = \frac{\sum_{i=1}^m (y'_i - y_{mean})^2}{\sum_{i=1}^m (y_i - y_{mean})^2} \quad (8)$$

式中: y_i 表示实际水位; y'_i 表示预测水位; y_{mean} 则为实际水位的平均值; m 表示测试样本数量。

3.2 试验环境及参数设置

所有试验均基于深度学习平台 PyTorch。为验证该模型的有效性, 将基于 Embedding-GRU 水库水位预测模型与原始 GRU、LSTM 以及较为流行的 GRU 变种算法 BiGRU 进行分析对比。为确保对比结果有效性, 在试验中其他网络模型参数均保持相同设置, 见表 2。

表 2 网络模型参数设置

Tab. 2 Parameter settings of network model

参数	设置
时间步长	1
批次大小	32
隐层节点数	64
网络层数	3
训练次数	10
损失函数	均方误差 E_{MS}

3.3 Embedding 的参数设置

本文模型的预测效果与 Embedding 阶段产出的向量相关, 因此首先对 Embedding 参数降雨量规模 s 与特征维度数量 n 进行对比试验, 根据数据集的降雨量规模及浙江省历史最大降雨量, 划定 Embedding 阶段的训练参数降雨量规模集合 s 为 {500, 550, 600, 650, 700, 750}, 精度为 $\text{mm} \times 10^{-1}$, 该参数表示每小时的降雨量在 $[0, s_i]$, i 为集合元素索引。即当降雨量规模 s_i 为 750 时, 表示每小时最大

降雨量为 75 mm。而根据 Chen 等^[30] 和工程上的经验, 建议降雨量规模 s 与特征维度数量 n 参照公式

$$n \approx s^{\frac{1}{4}} \quad (9)$$

为研究最优参数设置, 在采用控制变量法的前提下, 设置特征维度的范围扩展至 {2, 3, 4, 5, 6}。本次试验选择 E_{RMS} 指标, 该指标展示数据集真实值与预测值的误差大小, 直观展示预测效果, E_{RMS} 越小说明当前参数的预测效果越好, 试验结果见图 7。可以看到, 降雨量规模相同时, 维度为 {2, 3, 5} 时该模型效果较好, 平均 E_{RMS} 相比其他维度低 0.025; 特征维度相同时, 降雨量规模较小或者较大都会使 E_{RMS} 指标增加, 因为降雨量规模较小时, 得到的降雨量 Embedding 模型无法完全体现降雨气候特征, 而降雨量规模较大时, 则会使模型反映的特征更加稀疏, 所以降雨量规模为 $600 \text{ mm} \times 10^{-1}$ 时效果较优, 平均 E_{RMS} 为 0.142 49。为验证该模型的普适性, 在后续试验中, 将基于 Embedding-GRU 模型的参数将设置为 (600, 3), 即每小时降雨量规模为 $600 \text{ mm} \times 10^{-1}$, 特征维度设置为 3 维。




图 7 在不同维度和降雨量规模下的 E_{RMS}

Fig. 7 E_{RMS} with different dimension and rain fall

3.4 基于 Embedding-GRU 的水位预测结果

因原始数据采集间隔为 1 h, 且四岭水库的流域汇流面积只有 71.6 km^2 , 小流域汇流时间短, 故本文首先设置预见期为 1 h 进行对比试验。在预测下一

小时水位的对比试验中,为避免数据点密集,更好地展示试验对比效果,稀释试验的水位结果数据,每 24 h 选取一组数据进行绘制,试验结果见图 8 至图 15。图 8、图 10、图 12、图 14 为测试集中实际水位数据与预测水位数据的折线对比图,图 9、图 11、图 13、图 15 展示实际数据与预测数据的拟合程度。可以看到 4 种模型的预测能力都较为出色,能够相对准确地拟合真实水位数据,说明通过深度学习算法预测水库水位的方法是有效可行的。

4 种模型试验结果对比见表 3。总体上,3 种基于 GRU 的模型 (GRU, BiGRU, Embedding-GRU) 预测效果均优于 LSTM 模型,其中 Embedding-GRU 预测效果最优。由于本数据集原始特征维度较少,只有水位与降雨量,且受限于降雨量采集精度较低,Embedding-GRU 的试验指标均优于其他 3 种模型,其中 E_{MA} 和 E_{RMS} 指标分别平均下降 19.6% 和 7.7%。因此,该试验证明在 GRU 算法预测效果优于 LSTM 的同时,通过 Embedding 方法放大降雨量特征可以进一步有效减少预测误差,提高模型预测精度。




图 8 LSTM 模型预测效果
Fig. 8 Prediction results of LSTM model




图 9 LSTM 模型预测偏差
Fig. 9 Prediction bias of LSTM model




图 10 GRU 模型预测效果
Fig. 10 Prediction results of GRU model




图 11 GRU 模型预测偏差
Fig. 11 Prediction bias of GRU model




图 12 BiGRU 模型预测效果
Fig. 12 Prediction results of BiGRU model

为进一步验证 Embedding-GRU 模型的预测性能和泛化能力,进行基于每日降雨量总和预测次日水库水位的试验,即预见期为 1 d。对比算法仍为 LSTM, GRU 和 BiGRU,数据量为 5 a,共 1 826 组数据。同时进行两组对比试验,其中:一组以 2018 年至 2020 年的每日数据为训练样本,预测 2021 年至 2022 年每日水库水位;另一组以 2018 年至 2021 年的数据为训练样本,预测 2022 年的水库水位。图 16 各模型在不同测试集上的 E_{RMS} 坡度图展示基

于不同训练集各模型的 E_{RMS} 指标对比坡度, 由于在预测 2021 年和 2022 年水位的试验中训练集少于预测 2022 年水位的试验, 且进行 Embedding 的降雨量数据只有 3 年, 因此各算法的性能均有明显下降, 其中, 基于 Embedding-GRU 的 E_{RMS} 指标增加 120.3%, LSTM 模型的 E_{RMS} 指标增加 125.9%, GRU 模型的 E_{RMS} 指标增加 131.7%, BiGRU 模型的 E_{RMS} 指标增加 88.6%, 但仍在可接受范围内。




图 13 BiGRU 模型预测偏差

Fig. 13 Prediction bias of BiGRU model

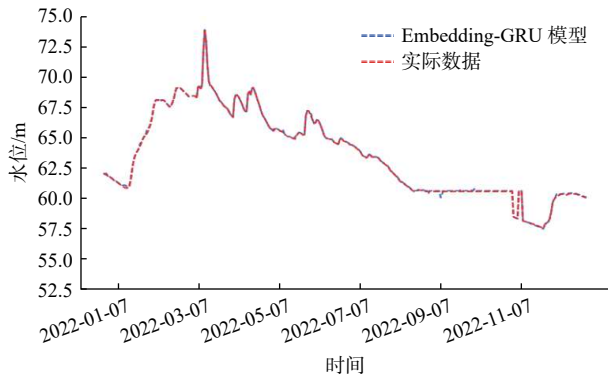


图 14 Embedding-GRU 模型预测效果

Fig. 14 Prediction results of Embedding-GRU model

试验结果见表 4。因数据集平均水位均大于 60 m, 当测试集为 2021 年和 2022 年水位数据时, 该模型的 E_{RMS} 值为 0.784 93, 偏差在 1.3% 以内, 仍属于较低值^[30]。 R^2 越接近 1, 说明模型拟合越好, 4 种模型的决定系数 R^2 最小值仍大于 0.91, 表明上述模型预测结果可靠, 且 Embedding-GRU 在两次试验中都具有更好性能, 因此证明基于 Embedding-GRU 模型在预测次日水库水位的场景下仍有相对较好预测效果, 具有较强泛化能力。

表 4 试验的水位预见期为 1 d, 为验证该模型在不同预见期的预测能力, 进一步进行预见期为 2、3、4、5、6 和 7 d 的多个时间水位预测对比试验, 测试

集设置为 2022 年水位数据。试验结果见图 17。随着预见期增加, 4 种模型的平均绝对误差 (E_{MA})、均方根误差 (E_{RMS}) 都有所增加, 决定性系数 R^2 逐步减小, 符合因预见期增长, 预测难度增大的客观事实。虽然预见期整体变长, 但在本试验所有时间的预见期应用中, Embedding-GRU 模型预测结果的 E_{MA} 、 E_{RMS} 指标全部小于 LSTM、GRU 和 BiGRU 模型, 见图 17(a) 和图 17(b)。




图 15 Embedding-GRU 模型预测偏差

Fig. 15 Prediction bias of Embedding-GRU model

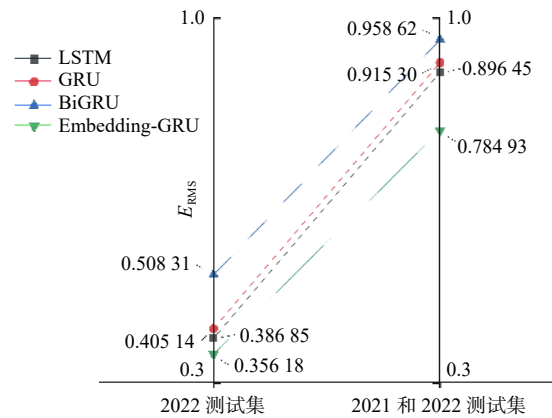


图 16 各模型在不同测试集上的 E_{RMS} 坡度图

Fig. 16 E_{RMS} slope plot on different test sets for each model

表 3 4 种模型的预测精度对比

Tab. 3 Comparison of prediction accuracy of four models

模型	E_{MA}	E_{RMS}	R^2
LSTM	0.096 76	0.169 26	0.997 65
GRU	0.072 26	0.149 17	0.998 17
BiGRU	0.079 44	0.146 84	0.998 23
Embedding-GRU	0.065 61	0.142 40	0.998 33

此外, 4 种模型预测结果的决定性系数 R^2 均呈现总体下降趋势, 见图 17(c)。但 R^2 最小值依旧保持在 0.8 以上, 仍具有一定预测可靠性。其中 Embedding-

GRU 模型预测结果的 R^2 指标下降最为缓慢,且在 的鲁棒性。
不同预见期中都表现最优,表现出该模型具有较强

表 4 4 种模型在不同测试集上的预测结果
Tab. 4 Prediction results of four models on different test sets

模型	2021年和 2022年 测试集			2022年测试集		
	E_{MA}	E_{RMS}	R^2	E_{MA}	E_{RMS}	R^2
LSTM	0.581 33	0.896 45	0.929 65	0.204 17	0.386 85	0.987 46
GRU	0.591 72	0.915 30	0.926 66	0.287 94	0.405 14	0.986 25
BiGRU	0.485 71	0.958 62	0.919 56	0.318 87	0.508 31	0.978 35
Embedding-GRU	0.361 68	0.784 93	0.946 06	0.202 34	0.356 18	0.989 37




图 17 各模型在不同预见期的预测结果

Fig. 17 The prediction results of each model at different forecast periods

4 结论

为弥补水库水位预测中水文数据单一特征的局限性,本文提出基于 Embedding-GRU 的水库水位预测模型,即通过 Embedding 方法放大降雨气候之间的特征,耦合轻量深度学习算法 GRU 预测水库水位。结论如下: Embedding-GRU 模型预测精度明显优于 LSTM、GRU 以及 BiGRU 等单一深度学习模型; Embedding-GRU 模型中 Embedding 参数需根据实际数据集进行对比试验确定; Embedding-GRU 模型在 7 d 以内多个时间的预见期预测表现出色,都有较好预测效果和泛化能力,充分证明该模型的有效性。

参考文献:

[1] 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. DOI: 10.13476/j.cnki.nsbdqk.2021.0085.
[2] 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. DOI: 10.13476/j.cnki.nsbdqk.2018.0002.

[3] 刘墨阳, 李巧玲, 李致家, 等. 基于小波分析的NARX神经网络在水位预测中的应用[J]. 南水北调与水利科技, 2019, 17(5): 56-63. DOI: 10.13476/j.cnki.nsbdqk.2019.0110.
[4] GHAREHBAGHI A, GHASEMLOUNIA R, AHMADI F, et al. Groundwater level prediction with meteorologically sensitive Gated Recurrent Unit (GRU) neural networks[J]. Journal of Hydrology, 2022, 612: 128262. DOI: 10.1016/j.jhydrol.2022.128262.
[5] 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. DOI: 10.3390/w15030587.
[6] 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. DOI: 10.3969/j.issn.1000-1379.2022.08.

- 014.
- [7] 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. DOI: [10.13476/j.cnki.nsbdqk.2022.0040](https://doi.org/10.13476/j.cnki.nsbdqk.2022.0040).
- [8] 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. DOI: [10.11988/ckyyb.20201266](https://doi.org/10.11988/ckyyb.20201266).
- [9] 刘艳, 张婷, 康爱卿, 等. Seq2Seq模型的短期水位预测[J]. *水利水电科技进展*, 2022, 42(3): 57-63. DOI: [10.3880/j.issn.1006-7647.2022.03.010](https://doi.org/10.3880/j.issn.1006-7647.2022.03.010).
- [10] 王海麟, 朱加良, 何正熙, 等. 基于卷积径向基网络的多变量水位预测模型[J]. *水力发电学报*, 2023, 42(3): 70-81. DOI: [10.11660/slfdb.20230307](https://doi.org/10.11660/slfdb.20230307).
- [11] 刘亚新, 樊启祥, 尚毅梓, 等. 基于LSTM神经网络的水电站短期水位预测方法[J]. *水利水电科技进展*, 2019, 39(2): 56-60, 78. DOI: [10.3880/j.issn.1006-7647.2019.02.011](https://doi.org/10.3880/j.issn.1006-7647.2019.02.011).
- [12] CHO M, KIM C, JUNG K, et al. Water level prediction model applying a Long Short-Term Memory (LSTM)-Gated Recurrent Unit (GRU) method for flood prediction[J]. *Water*, 2022, 14(14). DOI: [10.3390/w14142221](https://doi.org/10.3390/w14142221).
- [13] 陈珺, 黄燕华, 洪朋, 等. 基于机器学习模型的河道水位预测[J]. *水利水电科技进展*, 2023, 43(3): 9-14. DOI: [10.3880/j.issn.1006-7647.2023.03.002](https://doi.org/10.3880/j.issn.1006-7647.2023.03.002).
- [14] AZAD A S, SOKKALINGAM R, DAUD H, et al. Water level prediction through hybrid SARIMA and ANN models based on time series analysis: Red hills reservoir case study[J]. *Sustainability*, 2022, 14(3): 1843. DOI: [10.3390/su14031843](https://doi.org/10.3390/su14031843).
- [15] PAN M Y, ZHOU H N, CAO J Y, et al. Water level prediction model based on GRU and CNN[J]. *IEEE Access*, 2020, 8(1): 90-100. DOI: [10.1109/ACCESS.2020.2982433](https://doi.org/10.1109/ACCESS.2020.2982433).
- [16] 刘惟飞, 陈兵, 余周. 基于GRU-BP组合模型的湖泊水位预测方法探索[J]. *中国农村水利水电*, 2022(11): 58-65. DOI: [10.12396/znsd.220194](https://doi.org/10.12396/znsd.220194).
- [17] 胡昊, 马鑫, 徐杨, 等. 基于权重修正和DRSN-LSTM模型的向家坝下游水位多时间尺度预测[J]. *水利水电技术(中英文)*, 2022, 53(7): 46-57. DOI: [10.13928/j.cnki.wrahe.2022.07.005](https://doi.org/10.13928/j.cnki.wrahe.2022.07.005).
- [18] 王亦斌, 孙涛, 梁雪春, 等. 基于EMD-LSTM模型的河流量水位预测[J]. *水利水电科技进展*, 2020, 40(6): 40-47. DOI: [10.3880/j.issn.1006-7647.2020.06.008](https://doi.org/10.3880/j.issn.1006-7647.2020.06.008).
- [19] 刘晓伟, 哈明虎, 雷晓辉, 等. 基于GRA-NARX神经网络的泵站前水位预测模型[J]. *南水北调与水利科技(中英文)*, 2022, 20(4): 773-781. DOI: [10.13476/j.cnki.nsbdqk.2022.0079](https://doi.org/10.13476/j.cnki.nsbdqk.2022.0079).
- [20] 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. DOI: [10.16232/j.cnki.1001-4179.2020.10.016](https://doi.org/10.16232/j.cnki.1001-4179.2020.10.016).
- [21] PACCANARO A, HINTON G E. Learning distributed representations of concepts using linear relational embedding[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2001, 13(2): 232-244. DOI: [10.1109/69.917563](https://doi.org/10.1109/69.917563).
- [22] MIKOLOV T, SUTSKEVER I, CHEN K, et al. Distributed representations of words and phrases and their compositionality[J]. *Advances in neural information processing systems*, 2013, 23(10): 1-9. DOI: [10.48550/arXiv.1310.4546](https://doi.org/10.48550/arXiv.1310.4546).
- [23] BOJANOWSKI P, GRAVE E, JOULIN A, et al. Enriching word vectors with subword information[J]. *Transactions of the Association for Computational Linguistics*, 2017, 5(1): 135-146. DOI: [10.48550/arXiv.1607.04606](https://doi.org/10.48550/arXiv.1607.04606).
- [24] WANG J, HUANG P, ZHAO H, et al. Billion-scale commodity embedding for e-commerce recommendation in Alibaba [C]//Proceedings of the 24th ACM SIGKDD international conference on knowledge discovery & data mining. 2018: 839-848. DOI: [10.48550/arXiv.1803.0234](https://doi.org/10.48550/arXiv.1803.0234).
- [25] HUI B, ZHANG L, ZHOU X, et al. Personalized recommendation system based on knowledge embedding and historical behavior[J]. *Applied Intelligence*, 2022, 52(1): 1-13. DOI: [10.1007/s10489-021-02363-w](https://doi.org/10.1007/s10489-021-02363-w).
- [26] NUGROHO H, SURIPIN, HADIHARDAJA I K. The water level and outflow prediction using the artificial neural network (ANN) for the management of the reservoir flooding[J]. *International Journal of Innovative Technology and Exploring Engineering*, 2019(8): 4699-4706. DOI: [10.35940/ijitee.J9958](https://doi.org/10.35940/ijitee.J9958).

- 0881019.
- [27] CHUNG J, GULCEHRE C, CHO K H, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling[J]. *Eprint Arxiv*, 2014, 24(12): 1-9. DOI: [10.48550/arXiv.1412.3555](https://doi.org/10.48550/arXiv.1412.3555).
- [28] CHAKRABARTY A, PANDIT O A, GARAIN U. Context sensitive lemmatization using two successive bidirectional gated recurrent networks[C]//Proceedings of the 55 th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). 2017: 1481-1491. DOI: [10.18653/v1/P17-1136](https://doi.org/10.18653/v1/P17-1136).
- [29] ZHAO K X, LIU H, FAN W, et al. Autoemb: Automated embedding dimensionality search in streaming recommendations[C]//2021 IEEE International Conference on Data Mining (ICDM). IEEE, 2021: 896-905. DOI: [10.48550/arXiv.2002.11252](https://doi.org/10.48550/arXiv.2002.11252)
- [30] CHEN N, XIONG C, DU W, et al. An improved genetic algorithm coupling a back-propagation neural network model (IGA-BPNN) for water-level predictions[J]. *Water*, 2019, 11(9): 1795. DOI: [10.3390/w11091795](https://doi.org/10.3390/w11091795).

Reservoir level prediction based on Embedding-GRU model

YANG Tingting¹, YU Jiaying², XIAO Yao³, LUO Xiaoliang⁴

(1. Hebei Hydrologic Survey and Research Center, Shijiazhuang 050031, China; 2. School of Hydraulic Engineering, Zhejiang Tongji Vocational College of Science and Technology, Hangzhou 311231, China; 3. College of Aerospace Engineering, Chongqing University, Chongqing 400044, China; 4. Yuhang Hydrology and Water Resources Monitoring Station, Hangzhou 311115, China)

Abstract: The prediction of reservoir water level is of great significance in the daily operation and management of reservoir, the reinforcement of dam, the mitigation of flood disaster, and the protection of people's life and property safety. However, with the change of global temperature, the frequency of extreme weather increases and the uncertainty of abnormal rainfall increases, which lead to the lagging of reservoir level prediction methods relying on traditional engineering hydrology. Due to the high practicability of deep learning algorithms used in various fields, there are a few examples of domestic and foreign scholars using artificial intelligence to predict water levels. In order to make up for the shortcomings of single artificial intelligence model, some scholars also used the neural network model coupling method to study water level prediction, and a small number of scholars input a single variable to predict water level. The above research shows that it is feasible to use the coupled model for water level prediction, and the advantages of multiple models complement each other, and the prediction accuracy is improved to different degrees compared with the previous single model.

Considering various practical factors, the monitoring data of water level of Siling Reservoir was taken as an example and the coupling prediction model of water level of reservoir was put forward based on Embedding GRU on the condition that there was only a single characteristic rainfall, in order to provide a reference for realizing the high-precision prediction of water level with single characteristics. According to the rainfall scale of the data set and the largest rainfall in the history of Zhejiang Province, the training parameter rainfall scale sets of the Embedding stage is defined as {500,550,600,650,700,750} with the accuracy of $\text{mm} \times 10^{-1}$. In order to study the optimal parameter setting, the range of feature dimension setting was extended to {2,3,4,5,6} on the premise of adopting the control variates. The E_{RMS} indicator was selected for this experiment. To further validate the predictive performance and generalization ability of the Embedding GRU model, an experiment was conducted based on the total daily rainfall to predict the next day's reservoir water level. The comparison algorithm is still LSTM, GRU, and BiGRU, with a total of 1 826 sets of data with a data volume of 5 years.

Compared with other existing artificial intelligence models of reservoir water level, the prediction accuracy is higher and the scope of reservoir is wider. In the comparative experiment of predicting the next hour's water level,

the prediction ability of the four models was excellent, and they could fit the real water level data relatively accurately, which shows that the method of predicting the reservoir water level by deep learning algorithm is effective and feasible. By comparing of prediction accuracy of four models, the experiment proved that GRU algorithm is better than LSTM in prediction effect, and the embedding method can further effectively reduce the prediction error and improve the prediction accuracy of the model.

It is the Embedding method that enlarges the features between rainfall and climate, coupled with lightweight deep learning algorithm GRU to predict reservoir water level. Conclusions are as follows: (1) The prediction accuracy of the Embedding GRU model is obviously better than that of LSTM, GRU, BiGRU and other single deep learning models. (2) Embedding parameters in the Embedding GRU model shall be determined by comparative test according to the actual data set. (3) The Embedding-GRU model has excellent performance in predicting different period of multiple times within 7 days, and has good prediction effect and generalization ability, which fully proves the effectiveness of the model.

Key words: artificial intelligence; deep learning; water level prediction; Embedding; gated recurrent unit

(上接第 861 页)

- [20] UYSAL G. Product-and hydro-validation of satellite-based precipitation data sets for a poorly gauged snow-fed basin in Turkey[J]. *Water*, 2022, 14(17): 2758. DOI: 10.3390/w14172758.
- [21] HU Y M, CHEN T, LUO X Y, et al. Medium to long term runoff forecast for the Huai River basin based on machine learning algorithm[J]. *Earth Science Frontiers*, 2022, 29(3): 284-291. DOI: 10.13745/j.esf.sf.2021.10.2.
- [22] NIU X Y, LU C P, LU J Y, et al. Adaptability analysis of machine learning model in groundwater depth simulation[J]. *Journal of Hohai University (Natural Sciences)*, 2022, 50(4): 74-82. DOI: 10.3876/j.issn.1000-1980.2022.04.010.
- [23] ZHANG Y, YANG M X, LEI X H, et al. Research on annual runoff forecast of Danjiangkou Reservoir based on PCA-PSO-SVR[J]. *South-to-North Water Transfers and Water Science & Technology*, 2018, 16(5): 35-40. DOI: 10.13476/j.cnki.nsbdqk.2018.0122.
- [24] YIN G, YOSHIKANE T, YAMAMOTO K, et al. A support vector machine-based method for improving real-time hourly precipitation forecast in Japan[J]. *Journal of Hydrology*, 2022, 612: 128125. DOI: 10.1016/j.jhydrol.2022.128125.
- [25] ZHAN M, XUE H F, WANG H M, et al. Application of Bayesian neural network in short-term urban water consumption prediction[J]. *South-to-North Water Transfers and Water Science & Technology*, 2017, 15(3): 73-79. DOI: 10.13476/j.cnki.nsbdqk.2017.03.013.
- [26] MONEGO V S, ANOCHI J A, DE CAMPOS VELHO H F. South America seasonal precipitation prediction by gradient-boosting machine-learning approach[J]. *Atmosphere*, 2022, 13(2): 243. DOI: 10.3390/atmos13020243.
- [27] KARAMIZADEH S, ABDULLAH S M, HALIMI M, et al. Advantage and drawback of support vector machine functionality[C]//2014 international conference on computer, communications, and control technology (I4CT). IEEE, 2014: 63-65. DOI: 10.1109/I4CT.2014.6914146.
- [28] ANANDHI A, SRINIVAS V V, NANJUNDIAH R S, et al. Downscaling precipitation to river basin in India for IPCC SRES scenarios using support vector machine[J]. *International Journal of Climatology: A Journal of the Royal Meteorological Society*, 2008, 28(3): 401-420. DOI: 10.1002/joc.1529.
- [29] LI G, CHANG W, YANG H. A novel combined prediction model for monthly mean precipitation with error correction strategy[J]. *IEEE Access*, 2020, 8: 141432-141445. DOI: 10.1109/ACCESS.2020.3013354.