

基于卷积神经网络和长短期记忆网络的坝上水位精细化建模方法

席荣光¹, 申建建^{1*}, 王祥², 郭乐²

¹大连理工大学建设工程学院, 辽宁 大连

²中国长江电力股份有限公司梯级调度通信中心, 湖北 宜昌

收稿日期: 2024年3月15日; 录用日期: 2024年3月27日; 发布日期: 2024年4月28日

摘要

坝上水位是水电站调度运行的重要依据, 然而受调峰非恒定流的影响, 传统插值计算的水电站坝上水位与实际值存在较大的误差, 不利于水库水位的精细控制和实际调度。本研究采用最大互信息系数探索水电站坝上水位变化的关联因素, 并提出一种基于深度学习的CNN-LSTM模型计算方法, 实现了准确计算受调峰非恒定流影响的水电站坝上水位。为验证本文所提模型的有效性, 将其与传统法在三种评价准则进行对比, 结果表明, 所提的CNN-LSTM模型在汛期和枯水期的各种评价准则下均优于传统法, 模型计算结果更接近实际坝上水位。本文所提模型在水电运行时可有效避免计算水位不准确带来的控制风险, 降低水电站运行风险。

关键词

坝上水位, 非恒定流, 卷积神经网络, 长短期记忆网络

A Refined Modeling Method for Forebay Water Level Based on Convolutional Neural Network and Long Short-Term Memory Network

Rongguang Xi¹, Jianjian Shen^{1*}, Xiang Wang², Le Guo²

¹School of Infrastructure Engineering, Dalian University of Technology, Dalian Liaoning

²Cascade Dispatching Communication Center, China Yangtze Power Co., Ltd., Yichang Hubei

Received: Mar. 15th, 2024; accepted: Mar. 27th, 2024; published: Apr. 28th, 2024

Abstract

The forebay water level is an important basis for the scheduling and operation of hydropower plants. How-

作者简介: 席荣光(1998.04-), 甘肃天水人, 硕士研究生。研究方向为梯级水电站群优化调度, Email: rgxi@mail.dlut.edu.cn

*通讯作者 Email: shenjj@dlut.edu.cn

文章引用: 席荣光, 申建建, 王祥, 郭乐. 基于卷积神经网络和长短期记忆网络的坝上水位精细化建模方法[J]. 水资源研究, 2024, 13(2): 127-134. DOI: 10.12677/jwrr.2024.132015

ever, due to the influence of unsteady flow generated by peak shaving, the forebay water level calculated by the traditional interpolation method has a large error with the actual value, which is not conducive to the precise control of the water level and actual scheduling of hydropower plants. The maximum mutual information coefficient was used to explore the relevant factors of the forebay water level, and a deep neural network was designed to accurately calculate the forebay water level affected by peak shaving unsteady flow. To verify the effectiveness of the designed model, it was compared with traditional methods in three evaluation metrics. The results show that the proposed CNN-LSTM model outperforms traditional methods during flood and dry seasons, and the forebay water level obtained by CNN-LSTM is closer to the actual water level than the traditional method. The model proposed in this paper can effectively avoid the control risk caused by inaccurate calculation of the forebay water level and reduce the operation risk of the hydropower plant.

Keywords

Forebay Water Level, Unsteady Flow, Convolutional Neural Networks, Long Short-Term Memory Network

Copyright © 2024 by author(s) and Wuhan University.

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

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



1. 引言

水电是目前和未来电力系统中非常重要的灵活性调节电源，在电力系统中担任调峰[1]、调频[2]和平抑风光出力波动等任务[3]。水电在中国尤为重要，中国是世界上水电装机容量最大的国家，截至 2022 年底，水电装机容量达 41,350 万 kW，约占全国发电装机容量的 16%。其中，乌东德、白鹤滩、溪洛渡、向家坝和三峡水电站均跻身全球 10 大水电站之列，排名第一的长江干流某巨型水电站承担了中国湖北、湖南、江西、河南、广东、上海、江苏、浙江、安徽、重庆等十个省市电力供应任务，然而，如图 1 所示，在长江干流某巨型水电站参与电网调节时，水电站坝址附近水位变化剧烈，分厂尾水位间存在较大差异，对水电站精细化控制调度造成了不利影响。

目前已有许多学者开展了水电站精细化调度的研究，并取得了重要研究成果，张振东[4]基于 CNN-LSTM 模型对水电站尾水位进行准确预测。程潜[5]考虑水电站分厂尾水位差异建立两层嵌套短期优化方法。陈潇[6]采用 BP 神经网络对三峡水电站尾水位进行了精细化计算。然而以往关于水电站精细化调度的研究主要集中在尾水位，对调峰非恒定流引起的坝上水位波动水力问题鲜有关注，事实上，坝上水位是水电站调度运行的重要依据，准确计算坝上水位变化对于水电站精细化调度具有重要意义。如图 1 所示，在 2022 年 2 月 24 日，当水电站调




Figure 1. The forebay water level of the giant hydropower plant on the main stream of the Yangtze River

图 1. 长江干流某巨型水电站坝上水位过程

峰出力为 4000 MW 时, 坝上水位随出力的升高快速下降约 22 cm, 当出力降低时, 坝上水位随出力的下降而快速上升, 基于水量平衡方程的传统法则无法有效反映这种变化趋势, 从而导致水电站计算出力与实际出力间存在偏差, 影响电力供应。近年来, 深度学习方法在特征提取[7]、时序预测[8]领域取得广泛应用, CNN 和 LSTM 是其两类主要的网络结构。当前时段坝上水位受历史入库流量、出库流量等的影响, CNN 可以提取这些关联因素的特征, 此外, 坝上水位是一种时序变量, LSTM 可用于捕获其中的时序信息, 为此, 一种同时具有特征提取和时序信息捕获的 CNN-LSTM 模型[4]被用于计算水电站坝上水位, 以避免水电站运行时突破安全运行边界而对水电站和电力系统造成的不利影响。

2. 模型构建

2.1. 网络结构

卷积神经网络(CNN)被广泛应用于特征提取领域[7], 长短期记忆网络(LSTM)在时序数据预测等领域取得诸多实践[8]。本研究提出的 CNN-LSTM 网络用于计算水电站坝上水位日内变幅, 其中卷积神经网络用于提取历史数据间的特征信息, 长短期记忆网络用于提取其中的时序信息。

2.1.1. 卷积神经网络

卷积神经网络是一类包含卷积计算且具有深度结构的前馈神经网络[9], 可用于从输入中提取复杂的特征并将其转化为更高级的特征, 卷积层和池化层是其两类主要的网络结构。

1) 一维卷积层

$$y_{i,j}^l = \sigma \left(\sum_{m=1}^M w_{m,j}^l x_{i+m-1,j}^{l-1} + b_j^l \right) \quad (1)$$

式中: $y_{i,j}^l$ 表示第 l 层的输出向量; σ 表示激活函数; m 表示卷积核的数量; $w_{m,j}^l$ 表示卷积核的权重矩阵; $x_{i+m-1,j}^{l-1}$ 表示第 $l-1$ 层的输出向量; b_j^l 表示偏置矩阵。

2) 池化层

$$y_{i,j}^l = \max_{r \in R} y_{i \times T+r,j}^{l-1} \quad (2)$$

式中: $y_{i,j}^l$ 表示第 l 池化层的输出向量; $y_{i \times T+r,j}^{l-1}$ 表示第 $l-1$ 层的输出向量。

2.1.2. 长短期记忆网络

LSTM 可以提取时间序列数据特征, 并在其中引入门机制用于控制特征流通和损失从而有效解决 RNN 网络存在的长期依赖问题, LSTM 包含输入门、遗忘门、细胞转态和输入门四类结构。

1) 输入门:

$$i_t = \sigma(w_{xi}x_t + w_{hi}h_{t-1} + b_i) \quad (3)$$

$$g_t = \tanh(w_{xc}x_t + w_{hc}h_{t-1} + b_c) \quad (4)$$

2) 遗忘门:

$$f_t = \sigma(w_{xf}x_t + w_{hf}h_{t-1} + b_f) \quad (5)$$

3) 细胞状态:

$$c_t = f_t \odot c_{t-1} + i_t \odot g_t \quad (6)$$

4) 输出门:

$$o_t = \sigma(w_{xo}x_t + w_{ho}h_{t-1} + b_o) \quad (7)$$

$$h_t = o_t \odot \tanh(c_t) \tag{8}$$

式中： w_{xi} 、 w_{hi} 、 w_{xc} 、 w_{hc} 、 w_{xf} 、 w_{hf} 、 w_{xo} 、 w_{ho} 表示权重矩阵， b_i 、 b_c 、 b_f 、 b_o 表示偏置量， σ 、 \tanh 表示激活函数， \odot 表示向量 x 和 y 之间的点积。

2.1.3. 全连接层网络

全连接层通常用于放置在 CNN、LSTM 模型之后，每个输出节点都会连接到上一层的所有节点，用于综合前面网络层提取到的特征，可表示为：

$$y_t = f\left(\sum_{i=1}^l w_{ti}x_i + b_t\right) \tag{9}$$

式中： w_{ti} 表示权值矩阵， b_t 表示偏置量、 f 表示激活函数，如 *RELU*，*ELU* 等。

2.2. CNN-LSTM 模型框架

本研究基于 CNN 和 LSTM 模型构建了一种具有 7 层网络的 CNN-LSTM 模型，模型的整体框架及参数如图 2 所示。

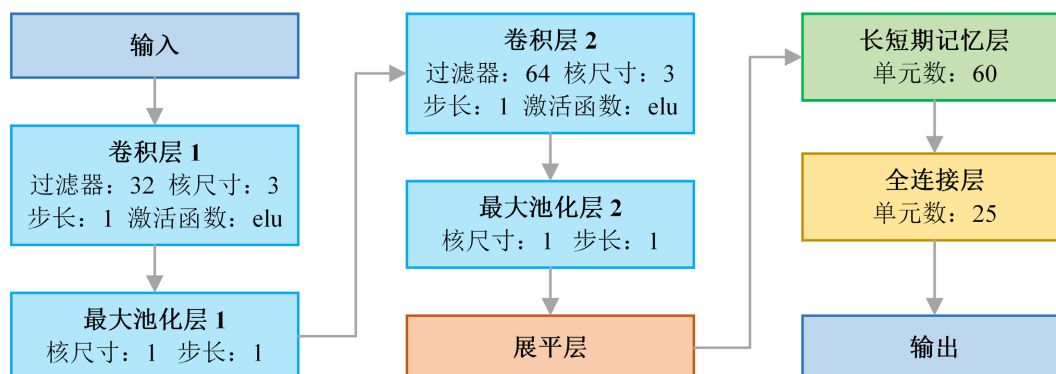


Figure 2. The framework of CNN-LSTM
图 2. CNN-LSTM 模型框架图

2.3. 特征选择

本研究采用最大互信息系数(MIC)衡量变量间的线性和非线性的相互关系，其可以被描述为：

$$I(X, Y) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log_2 \frac{p(x, y)}{p(x)p(y)} \tag{10}$$

$$\text{MIC}(X, Y) = \max_{xy < n^a} \frac{I^*(X, Y)}{\log_2 \min(x, y)} \tag{11}$$

式中： $I(X, Y)$ 表示随机变量 X 和 Y 的互信息， $p(x, y)$ 表示变量 x 和 y 的联合概率密度； $p(x)$ 和 $p(y)$ 分别表示变量 x 和 y 的边缘概率密度。 $\text{MIC}(X, Y)$ 表示变量 X 和 Y 的最大互信息系数， $I^*(x, y)$ 为固定网格数下所得的最大互信息值， n 表示数据集 D 的样本个数， a 通常根据经验设置为 0.6。

2.4. 评价准则

本文选用平均绝对值误差(MAE)、均方根误差(RMSE)、和对称平均绝对百分比误差(SMAPE)评价所提模型在坝上水位调峰变幅计算的精度。

1) 平均绝对值误差(MAE)

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \times 100\% \tag{12}$$

式中： \hat{y}_i 表示在时段 t 的预测水位， y_i 表示在时段 t 的实际观测水位， n 表示验证集的数量。其中当 MAE 值越小，模型预测精度越高。

2) 均方根误差(RMSE)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \tag{13}$$

式中：其中当 RMSE 越小，模型预测精度越高。

3) 对称平均绝对百分比误差(SMAPE)

$$SMAPE = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{(|\hat{y}_i| + |y_i|)/2} \times 100\% \tag{14}$$

式中：其中当 SMAPE 越小，模型预测精度越高。

3. 应用实例

3.1. 工程背景

长江流域是世界第三大流域，长江干流全长 6300 km，汛期为 5 月到 10 月，长江干流某巨型水电站是长江干流关键控制性水利枢纽工程，以防洪为主要任务，兼顾有发电、航运、生态等综合利用效益。长江干流某巨型电站总装机容量 22,500 MW，是世界上规模最大的水电站，电站保证出力为 4990 MW，正常蓄水位 175 m，防洪限制水位 145 m，是我国“西电东送”和“南北互供”的骨干电源点。

3.2. 参数选择

本节首先通过特征分析确定了 CNN-LSTM 模型的输入特征，并通过随机优化法优化模型结构及其参数。其中 2013 年~2021 年实际运行数据为计算训练集，2022 年数据为测试集。

3.2.1. 输入特征构建

为分析水电站调度期内调峰时坝上水位日内变幅(相对于 0 点水位)的关联因素，选择训练集中历史入库流量、出库流量、全厂出力、尾水位、水头、坝上水位、坝上水位日内变幅作为候选特征，这些候选特征在调度期内、调度期间与坝上水位日内变幅的最大互信息系数(MIC)详见表 1 所示，结果表明：

Table 1. The MIC values between candidate features and the intraday variation of the forebay water level

表 1. 各候选特征与坝上水位日内变幅间的最大互信息系数表

MIC	t	$t-1$	$t-2$	$t-3$	$t-7$	$t-24$	$t-31$	$t-48$	$t-72$
入库流量	0.110	0.106	0.105	0.106	0.156	0.095	0.127	0.080	0.068
出库流量	0.257	0.208	0.146	0.105	0.120	0.241	0.117	0.223	0.213
全厂出力	0.350	0.318	0.258	0.183	0.190	0.334	0.183	0.321	0.319
尾水位	0.059	0.040	0.029	0.035	0.056	0.059	0.052	0.060	0.055
水头	0.059	0.059	0.061	0.064	0.070	0.059	0.071	0.054	0.049
坝上水位	0.101	0.094	0.090	0.085	0.085	0.087	0.082	0.087	0.077
日内变幅	1.000	0.687	0.462	0.301	0.071	0.462	0.042	0.382	0.308

1) 各候选特征以 24 h 为周期, 且同一周期的相邻时段和相邻周期的同时段相关性较高, 如时段 t 的全厂出力与日内水位变幅的相关性为 0.350, 时段 $t-24$ 全厂出力与日内水位变幅的相关性为 0.334;

2) 入库流量具有明显的滞后性, 滞后时段约为 7 h (MIC = 0.156); 出库流量、全厂出力与坝上水位日内变幅间无明显滞后性;

3) 尾水位(MIC = 0.059)、水头(MIC = 0.059)、坝上水位(MIC = 0.101)与坝上水位日内变幅间相关性较差。

目前长江干流某巨型水电站短期入库预报精度高, 电站负荷由调度机构根据电网负荷需求确定。因此, 本研究结合上述特征分析结果, 选择 $t-7$ 到 $t+17$ 时段的入库流量、 $t-24$ 到 t 时段的出库流量、 t 到 $t+24$ 时段的全厂出力、 $t-24$ 到 t 时段的坝上水位日内变幅组合形成新的输入特征, 并采用新的组合特征计算时段 t 到 $t+24$ 的日内水位变幅。

3.2.2. 超参数优化

本研究中采用工具中的随机优化方法[10]确定 CNN-LSTM 模型结构及其参数, 优化后的 CNN-LSTM 模型结构及参数如图 2 所示, 模型的学习率为 0.001, 批大小为 32。

3.3. 结果分析

3.3.1. 不同方法计算结果对比

本节主要验证研究所提的 CNN-LSTM 模型在多种评价准则下计算水电站坝上水位时的有效性, 并与传统水量平衡方程和水位库容曲线插值法进行比较分析, 表 2 列出了 2022 年测试集汛期和枯水期采用 CNN-LSTM 模型和插值法计算的水电站坝上水位各评价准则的结果, 并得出如下结论:

Table2. The evaluation metrics of CNN-LSTM and the traditional method

表 2. 坝上水位 CNN-LSTM 法和插值法评价准则对比

时期	评价准则	CNN-LSTM	插值法
枯水期	MAE	0.030	0.074
	RMSE	0.039	0.093
	SMAPE	0.014	0.021
汛期	MAE	0.046	0.120
	RMSE	0.067	0.163
	SMAPE	0.018	0.027

1) CNN-LSTM 模型在汛期和枯水期的各种评价准则下均优于传统法, 表明由 CNN-LSTM 模型得到的水电站坝上水位接近实际坝上水位;

2) CNN-LSTM 模型和插值法在枯水期各评价准则均小于在汛期时的各评价准则, 这是由于汛期时, 水电站坝上水位影响因素更多, 如水电站泄流方式、动防洪库容和防洪调度规则等, 这导致汛期较枯水期更难准确计算水电站坝上水位。

3.3.2. 模型结果可视化

为进一步验证本研究提出的 CNN-LSTM 模型在计算水电站坝址附近水位波动的精度, 图 3 对测试集 2022 年枯水期某日和汛期某日的计算结果进行了可视化, 结果表明:

1) 当水电站参与调峰时, 水电站坝址附近会发生跌水现象, 当电站出力调峰增加时, 坝前水位降低, 水电站减小出力时, 坝址附近水位会短时间内上升, 采用插值法无法有效反映坝前水位的波动。




Figure 3. The process of power output and forebay water level on the dry and flood season of the test set
图 3. 测试集的枯水期和汛期某日水位和出力过程图

2) 在枯水期某日, 当出力增加 2400 MW 时, 水位较传统法降低约 0.23 m, 出力增加 3600 MW 时, 水位较传统法降低约 0.27 m; 在汛期某日, 传统插值法计算的坝上水位较实际最大低 0.49 m, 采用 CNN-LSTM 模型计算的坝上水位接近水电站实际运行水位。

因此, 在实际运行时采用 CNN-LSTM 模型计算水电站坝上水位可有效避免突破死水位、防洪限制水位等安全边界, 降低水电站运行风险。

4. 结论

本文针对水电站调峰运行时坝址附近水位波动剧烈的实际问题, 分析了传统法与实际水位间存在误差的原因, 并构建了基于深度学习方法的水电站坝上水位 CNN-LSTM 计算模型。以长江干流某巨型水电站为研究实例, 本文所提的 CNN-LSTM 模型在枯水期和汛期较传统法具有更高的精度, 所得坝上水位更接近实际坝上变化趋势, 在水电站运行时能有效避免计算水位不准确带来的控制风险, 降低水电站运行风险。

基金项目

中国长江电力股份有限公司科技项目(Z242202001), 国家自然科学基金项目(52079014)。

参考文献

- [1] 申建建, 陈光泽, 魏巍, 等. 耦合联动分析理论的多调峰指标水电短期调度模型[J]. 水利学报, 2021, 52(8): 936-947.
- [2] 余意. 电力市场下梯级水电系统短期优化调度及风险控制[D]: [博士学位论文]. 武汉: 华中科技大学, 2021.
- [3] 郭怿. 适应跨区域外送消纳的水风光储互补短期协调运行研究[D]: [博士学位论文]. 西安: 西安理工大学, 2024.
- [4] ZHANG, Z. D., QIN, H., YAO, L. Q., et al. Downstream water level prediction of reservoir based on convolutional neural network and long short-term memory network. *Journal of Water Resources Planning and Management*, 2021, 147(9): 04021060. [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0001432](https://doi.org/10.1061/(ASCE)WR.1943-5452.0001432)
- [5] CHENG, Q., MING, B., LIU, P., et al. Solving hydro unit commitment problems with multiple hydraulic heads based on a two-layer nested optimization method. *Renew Energy*, 2021, 172: 317-326. <https://doi.org/10.1016/j.renene.2021.02.126>
- [6] CHEN, X., ZHOU, J. Z., JIA, B. J., et al. Novel and robust outflow forecasting methods for upstream large hydropower stations. *Journal of Hydrology*, 2022, 609(12): 127742. <https://doi.org/10.1016/j.jhydrol.2022.127742>
- [7] ZHOU, D. X. Deep distributed convolutional neural networks: Universality. *Analysis and Applications*, 2018, 16(6): 895-919. <https://doi.org/10.1142/S0219530518500124>
- [8] SHI, X. J., CHEN, Z. R., WANG, H., et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *Advances in Neural Information Processing Systems 28 (NIPS 2015)*, Montreal, 802-810.

- [9] LE CALLET, P., VIARD-GAUDIN, C. and BARBA, D. A convolutional neural network approach for objective video quality assessment. IEEE Transactions on Neural Networks, 2006, 17(5): 1316-1327. <https://doi.org/10.1109/TNN.2006.879766>
- [10] BERGSTRA, J., BENGIO, Y. Random search for hyper-parameter optimization. Journal of Machine Learning Research, 2012, 13: 281-305.