

基于双向 LSTM 神经网络的站点周边水位预测系统设计

姚 晔, 许锡伟, 管剑波, 葛旭初
(宁波市轨道交通集团有限公司, 浙江 宁波 315000)

摘要: 为提升水利设施监测站点周边水位预测的准确性, 设计基于双向 LSTM 神经网络的站点周边水位预测系统; 系统硬件部分设计了周边水系查询体系与水位记录装置; 系统软件根据初始参数定义结果建立 LSTM 神经网络布局模型, 设计双向 LSTM 解码器, 其连接闭环能够有效地提高模型的预测性能和稳定性; 采集水位数据并进行清洗处理, 利用清洗后的数据对象建立一维水动力模型, 计算水系糙率, 确定流量与延时时间的数值关系, 将上述参数作为输入值对双向 LSTM 模型进行训练, 实现水位信息的预测; 实验结果表明, 在实验水系区域内, 所提方法 5 月份、6 月份的水位记录数据与原始水位数据之间的差值始终为零, 拟合误差也为零; 而对比方法中基于 DWT-LSTM 的水位预测模型的 5 月份、6 月份的水位差值分别为 1.9 m、1.1 m; 抽水蓄能引水型水位监测系统的 5 月份、6 月份的水位差值分别为 3.0 m、2.4 m。

关键词: 双向 LSTM 神经网络; 水位预测; 水系查询; 数据清洗; 水动力模型; 水系糙率

Design of Water Level Prediction System Around Station Based on Bidirectional LSTM Neural Network

YAO Ye, XU Xiwei, GUAN Jianbo, GE Xuchu
(Ningbo Rail Transit Group Co., Ltd., Ningbo 315000, China)

Abstract: To improve the accuracy of water level prediction around water conservancy facility monitoring stations, a water level prediction system for station surroundings based on bidirectional long short-term memory (LSTM) neural network is designed. The hardware part of the system is designed with the peripheral water system query system and the water level recording device; The system software establishes the LSTM neural network layout model based on the initial parameter definition results, designs the bidirectional LSTM decoder, and its connection loop can effectively improve the predictive performance and stability of the model. The system collects the water level data and performs cleaning processing. The cleaned data object is used to establish the one-dimensional hydrodynamic model, calculate the roughness of the water system, determine the numerical relationship between flow rate and delay time, and train the bidirectional LSTM model with the above parameters as the input values to achieve the prediction of water level information. Experimental results show that within the experimental water system area, the difference between the water level recorded data in May and June using the proposed method and the original water level data is always zero, and the fitting error is also zero. The water level difference between May and June based on the DWT-LSTM water level prediction model in the comparison method is 1.9 m and 1.1 m, respectively; The water level difference between May and June for the pumped storage and diversion water level monitoring system is 3.0 m and 2.4 m, respectively.

Keywords: bidirectional LSTM neural network; water level prediction; water system inquiry; data cleaning; hydrodynamic model; drainage roughness

0 引言

随着社会经济的发展和气候变化的影响, 水资源的分布和利用方式越来越受到人们的关注。水位预测作为水资源管理的重要环节, 对于水灾预警、水资源合理配置、水库安全运行等方面具有重要意义。站点周边水位预测系统设计的站点通常是指水文监测站或水务监测站等水利设施。这些站点的作用是对水位进行实时监测, 以保障水域安全

和水资源管理的需要^[1]。周边水位预测的意义在于: 水灾预警: 通过监测水库水位的实时变化, 根据设定的阈值和警戒线进行预警, 以防止洪水灾害的发生, 减少人员财产损失; 提供准确的水位数据, 帮助水资源管理部门了解水库储量和供水情况, 合理调度水库的放水和蓄水, 优化水资源的利用和分配。实时监测和预警水库水位变化, 及时发现任何异常情况, 如水位异常上升或泄洪设施出现故障等, 避免潜在的安全隐患, 并采取及时措施进行修复和处

收稿日期: 2023-10-10; 修回日期: 2023-12-04。

作者简介: 姚 晔(1973-), 男, 硕士, 高级工程师。

引用格式: 姚 晔, 许锡伟, 管剑波, 等. 基于双向 LSTM 神经网络的站点周边水位预测系统设计[J]. 计算机测量与控制, 2024, 32(11): 18-24, 33.

理; 为相关决策者提供重要的参考数据, 包括洪水防范和应急管理的决策, 如轮汛调度、人员疏散、救援资源调配等, 提高决策的科学性和效率; 监测水库水位对周边环境的影响, 及时的水位监测和预警可以采取保护措施保护环境, 减少因水库引起的环境破坏。因此, 设计一个站点周边水位预测系统具有重要的实际应用价值和社会经济效益。

在区域性水系环境中, 如何控制水位记录数据与原始水位数据之间的差值水平, 从而实现对周边水系特点的准确预测成为了一项亟待解决的问题。倪汉杰^[2]等人提出基于 DWT-LSTM 的水位预测模型, 在安全通航的前提下, 定义内河周边水系环境的水位特征, 联合小波分析和长短时记忆分析原则, 建立完整的耦合性神经网络模型, 再联合 BP 神经模型, 确定既定时刻点处的水位值预测结果。冯凌云^[3]等人提出抽水蓄能引水型水位监测系统, 借助 TURCK (图尔克) 型智能压力传感器, 实施对水位的实时测量, 联合 S7-1200 PLC 主控器, 完成对水体传输信息的采集, 利用 TIA Portal V15 软件整合所有测量数据, 从而定义具体的实时水位预测方案。然而在水系覆盖面积相对较大的情况下, 上述两种方法的应用并不能保证水位记录数据与原始水位数据的无误差拟合, 故而也就无法达到实际需求标准。

双向 LSTM 神经网络是以非单向时间循环条件为基础定义的神经网络结构, 能够解决一般循环模式过于依赖门限期望值的问题。相较于单向循环网络或传统神经循环模型, 双向 LSTM 神经网络中链式结构的连接形式更为复杂, 一个标准的 RNN 节点可以同时与多个单元性组织保持对应连接关系^[4]。在数据信息传输过程中, 已存在于信道组织内的数据对象不会出现明显堆积的情况, 且无论数据样本能否被传输至目标标记位置处, 组织体系对于数据参量的承载能力与实时传输能力都不会发生变化。利用双向 LSTM 神经网络的应用优势, 设计一种新型的站点周边水位预测系统, 系统硬件设计了周边水系查询体系与水位记录装置。系统软件利用确定的初始参数和结果, 设计了 LSTM 神经网络的布局模型, 并引入了双向 LSTM 解码器。双向 LSTM 解码器在信息流动中形成闭环连接, 提高了模型的预测性能和稳定性。将采集到的水位数据进行清洗处理, 确保数据的准确性和可靠性。通过建立一维水动力模型获取水系糙率计算结果, 确定了流量与延时时间之间的数值关系, 以这些参数作为神经网络的输入值, 对双向 LSTM 模型进行训练, 实现对水位信息的预测。结合了软、硬件结构, 将神经网络模型与实际硬件设备相结合, 实现了基于双向 LSTM 神经网络的站点周边水位预测系统的设计。

1 站点周边水位预测系统硬件设计

对于站点周边水位预测系统执行方案的设计, 其硬件部分包括周边水系查询体系与水位记录装置, 软件部分包括 LSTM 神经网络布局与双向 LSTM 解码器模型定义, 本章节针对这两部分单元结构的具体设计方法展开研究。

1.1 周边水系查询体系

周边水系查询体系负责记录区域性水体环境中的泥沙量、水体输入量、水体输出量、泥沙沉淀量、水资源回流量等物理参数, 可以使用多种方法获取水体环境的物理参数, 例如, 可以通过水体采样和分析来获取泥沙量的数据。在采样时, 需要选择具有代表性的水样, 并使用适当的分析方法来测量其中的泥沙含量; 通过测量输入河流的水量、水质等参数来获取水体输入量的数据; 通过测量河流出口的水量、水质等参数来获取水体输出量的数据; 通常需要长期监测水体中的泥沙含量, 并观察其变化趋势, 从而推断出泥沙沉淀量的数据; 通过在河流或水库中设置观测站点, 测量水资源回流的水量和水质等参数来获取数据。在获取上述物理参数的基础上, 可以借助信道组织, 将所得数据信息回传至系统中控设备之中, 以便于主机元件能够对站点周边水位情况进行实时预测。回流泵吸收沉淀池内流出的含有泥沙的浑浊水, 在吸力作用下, 浑浊水进入混凝槽, 并随着水循环继续参与后续沙水分离流程。澄清水悬浮于混有泥沙的浑浊水溶液上端, 由于挡板装置的存在, 澄清后的水系资源可进行自然沉降, 不会再与混凝槽中的浑浊溶液发生混合^[5]。在回流泵运行过程中, 为避免振动过大导致泥沙进入混凝槽之中, 沉淀池底部设有格栅式结构, 以起到过滤大型泥沙或石块的目的。为满足站点周边水位预测系统的运行需求, 分离后的泥沙与水体资源进入不同的传输通路之中, 由于粉絮状泥沙的吸附性较强, 所以为了得到良好的水体沉降效果, 还应在混凝槽中添加一定量的助凝剂^[6]。详细的周边水系查询体系结构模型如图 1 所示。

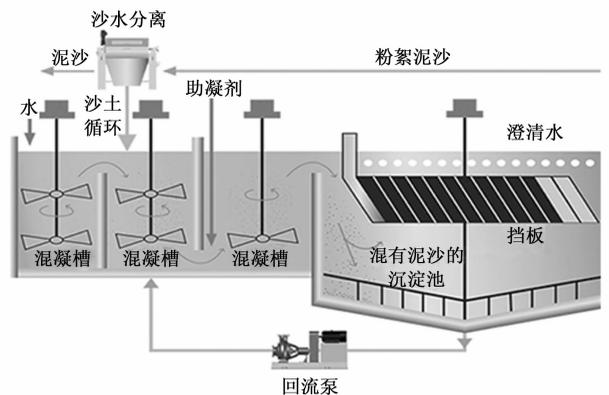


图 1 周边水系查询体系的结构简图

周边水系查询体系还可以将混合在一起的沙、水分离开来, 这就使得系统主机在记录水位数据时, 不会因泥沙影响而出现记录数值过大的情况。

1.2 水位记录装置

水位记录装置是一种柱状结构体, 根据浮标内 PLC 传感元件所采集到的水位信息, 调节水位传感器, 从而推动调节器使其出现上升或下降行为, 并以此带动置码桩的上浮或下沉, 整个行为流程的数值变化状态与码杆元件的数

值变化情况保持一致。位移杆将码杆与水位传感器连接在一起,当传感器元件接收到浮标所采集到的水位信息后,调节器进入行为状态,当前情况下,置码桩随之快速协调,直至码杆示数水平与位移杆上的示数刻度保持一致^[7]。置码桩具有紧旋、松弛两种行为模式,松弛状态下,码桩所受重力水平增大,码杆向着置码桩方向倾斜,表示浮标所监测区域内的水位相对较高;紧旋状态下,码桩所受重力水平减小,码杆向着置码桩的反方向倾斜,表示浮标所监测区域内的水位相对较低^[8]。距离移动标志物连同支撑杆、锁扣与位移杆右侧的固定装置相连,当锁扣紧扣于支撑杆时,杆体的倾斜运动能力较弱,表示移动标志物的水平运动能力较弱,这也指示了浮标所监测区域内的水位相对较低。具体的水位记录装置结构模型如图 2 所示。

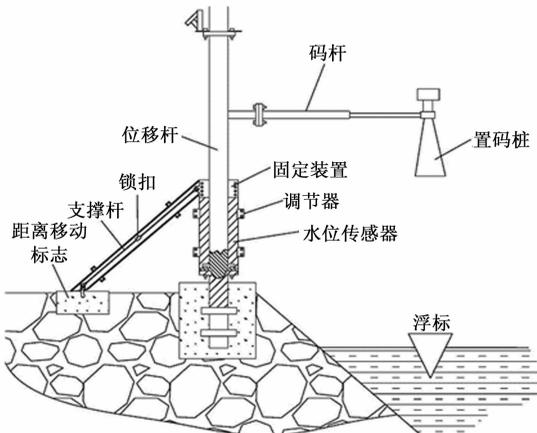


图 2 水位记录装置结构模型

随着浮标的上升或下降,水位传感器、位移杆、码杆元件的示数水平也在不断发生变化,这就表示整个水位记录装置是一个统一的结构体系,任意一个测试值的变化,都会带来不同的水位监测结果。

2 软件部分设计

在基于双向 LSTM 神经网络的站点周边水位预测系统软件部分,在训练模型之前,首先进行双向 LSTM 神经网络的初始参数选择,最佳的初始参数设置,以使模型能够更好地适应数据并准确地预测水位变化;然后构建 LSTM 神经网络布局模型,以提升模型的表达能力和学习能力;在水位预测系统中,由于水位的变化受到多个因素的影响,仅使用单向 LSTM 模型可能无法充分捕捉到时序数据的相关特征。双向 LSTM 解码器是一种将历史信息和未来信息结合起来进行预测的模型,可以在保持信息流动的同时提供更全面的时序信息。然后,采集水位数据并进行数据清洗处理,作为训练集用于训练神经网络模型。其次,确定双向 LSTM 神经网络的输入参数,通过构建一维水动力模型获取水系糙率,确定流量与延时时间关系,讲这些参数作为双向 LSTM 模型的输入值。最后对双向 LSTM 模型进行训练,实现站点周边水位进行预测。

2.1 双向 LSTM 神经网络

通过使用 LSTM 神经网络模型,选择初始参数,构建 LSTM 神经网络布局模型,可以捕捉到时间序列数据中的长期依赖关系,并能够对未来的水位趋势进行预测。设计双向 LSTM 解码器,双向 LSTM 解码器的连接闭环能够有效地提高模型的预测性能和稳定性。

2.1.1 初始参数选择

初始参数决定了双向 LSTM 神经网络对站点周边水位预测系统的作用能力,在周边水系查询体系、水位记录装置能够准确标记水位信息的情况下,该项物理量的取值始终属于 $(1, +\infty)$ 的数值区间。在双向 LSTM 神经网络模型中,初始参数的取值越大就表示系统主机对水位预测信息的处理能力越强,由于站点周边水位预测系统运行过程中,主机元件可以同时测得水位记录数据与原始水位数据,所以求解双向 LSTM 神经网络初始参数时,要求所有水位信息测量值必须属于同一周边水系环境^[9]。

规定 O 表示基于双向 LSTM 神经网络的水位信息取样向量,其计算式如下:

$$O = \frac{1}{\chi} \sum_{\alpha=1}^{+\infty} \sqrt[p_{\delta} + p_{\epsilon}]{\quad} \quad (1)$$

χ 表示水位记录数据测量值、原始水位数据测量值之间的对比关系定义阈值, α 表示水位信息测量值标记参数, δ 、 ϵ 表示两个随机选取的水位深度定义项,且 $\chi \neq 0$ 、 $\delta \neq \epsilon$ 的不等式取值条件同时成立, p_{δ} 表示基于参数 δ 的水位信息实时取值, p_{ϵ} 表示基于参数 ϵ 的水位信息实时取值。

利用公式 (1),可将双向 LSTM 神经网络的初始参数计算式表示为:

$$I = O \left[\sum_{-\infty}^{+\infty} \beta (i_{\max} - i_{\min})^2 \right]^{\dagger} \quad (2)$$

式中, i_{\max} 表示水位深度差的最大取值, i_{\min} 表示水位深度差的最小取值, β 表示基于双向 LSTM 神经网络的水位深度差识别参数, γ 表示随机条件下的水位深度标记项指征。在双向 LSTM 神经网络中,站点周边水位预测系统的最主要运行目的是缩小水位记录数据与原始水位数据之间的拟合误差,因此在计算初始参数时,还应避免水位记录装置浮标出现过度上升或下降的情况^[10]。

2.1.2 LSTM 神经网络布局模型

LSTM 神经网络是由 Encoder 终端、GPU 节点、layers 终端共同组成的一体化结构模型,其布局形式如图 3 所示。

1) Encoder 终端: LSTM 神经网络的 Encoder 终端提供了系统运行所必需的站点周边水位预测信息,为 GPU 节点的接入提供了稳定的网络环境^[11]。相较于 LSTM 神经单元的单循环模式,Encoder 终端定义了与水位预测数据相关的双向循环模式,可以在提取 GPU 节点内信息传输参量的同时,使站点周边水位预测系统主机在 LSTM 神经网络中保持相对稳定的运行状态。

2) GPU 节点: LSTM 神经网络的 GPU 节点负责在 Encoder 终端、layers 终端之间传输站点周边水位预测信

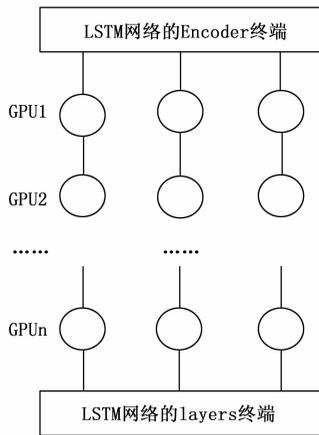


图 3 LSTM 神经网络的布局结构

息, 具有较强的数据整合能力。在水位预测系统运行过程中, 该节点组织可以直接获取周边水系查询体系、水位记录装置中的数据信息测量值, 并能够在 LSTM 神经网络专属信息通路的配合下, 将已测得的水位数据传输至预测系统的既定平台单元之中, 以便于主机元件的直接调取与利用^[12]。

3) layers 终端: LSTM 神经网络的 layers 终端负责整合双向网络体系中的所有站点周边水位预测数据, 是 GPU 节点的下级反馈结构。

设 φ 表示 LSTM 神经网络对于站点周边水位预测数据筛选参数, φ 表示 LSTM 神经网络中的数据信息对象双向传输向量, \bar{u} 表示站点周边水位预测数据在单位测量周期内的累积均值, \tilde{y} 表示站点周边水位预测数据在神经网络体系 GPU 节点单元中的响应特征。在上述物理量的支持下, 联立公式 (2), 推导 LSTM 神经网络布局模型的定义式为:

$$U = \varphi \times \left| \frac{(\varphi + 1)\bar{u}}{I} \right|^2 \times \tilde{y} \quad (3)$$

站点周边水位预测系统运行过程中, Encoder 终端、GPU 节点、layers 终端对于水位测量信息的识别能力完全相同, 因此只要保证数据样本的准确输入, 双向 LSTM 神经网络就不会出现错误识别水位测量值的情况。

2.1.3 水位预测系统的双向 LSTM 解码器

双向 LSTM 解码器负责深度加工系统主机采集到的站点周边水位预测数据, 借助 AttV 编码介质, 完成对数据样本的分配处理, 并可以联合 LSTM 神经节点, 定义具体的 Softmax 数据编码条件。AttV 编码介质对于系统主机所采集到的站点周边水位预测数据具有普遍性辨识能力, 前者按照 LSTM 神经网络布局模型, 完成对数据样本的取样, 特别是在 Encoder 终端、GPU 节点、layers 终端保持完全闭合连接状态的情况下, 只有保障预测数据分配结果的准确性, 才能实现对区域性水系环境中水位情况的实时预测^[13]。LSTM 神经节点与 AttV 编码介质之间的站点周边水位预测数据保持双向传输特性, 且每一个神经节点对象

只能与一个 AttV 介质保持连接关系。图 4 反映了双向 LSTM 解码器内站点周边水位预测数据样本的具体编码原则。

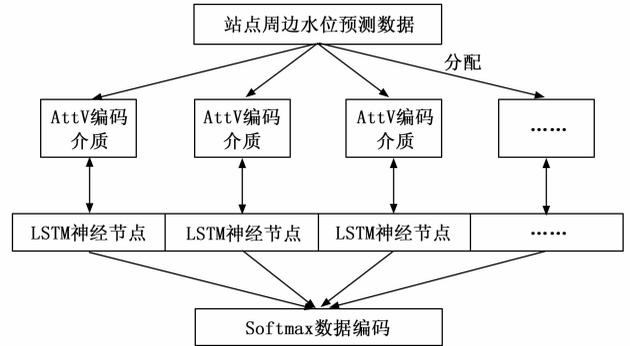


图 4 双向 LSTM 解码器内的数据样本编码原则

规定 t 表示站点周边水位预测数据的实时分配系数, \bar{R} 表示 AttV 编码介质内的水位预测数据分布特征, ι 表示 LSTM 神经节点、AttV 编码介质之间的数据对象双向转存参数, ΔT 表示站点周边水位预测数据的单位编码周期, 联立公式 (3), 可将双向 LSTM 解码器标准连接条件表示为:

$$Y = \int_{t=1}^{+\infty} \bar{R}^{(\iota)} \cdot U \cdot |\Delta T| dU \quad (4)$$

双向 LSTM 神经网络是支持站点周边水位预测系统运行的软件条件, 因此在实施数据样本编码时, 还应保证 AttV 编码介质与 LSTM 神经节点之间水位预测信息双向传输关系的稳定性^[14]。

2.2 水位数据采集

在双向 LSTM 神经网络的支持下, 采集水位数据, 双向 LSTM 神经网络对于水位数据的采集是按照断面里程与底高程标记条件, 在不同水系断面内, 取得可用来描述水文深度的数据信息参量。对于站点周边水位预测系统而言, 为保证采集到数据能够充分表现出站点周边水系环境中的水位特征, 至少应设置如表 1 所示的几个断面组织。

表 1 水位数据采集标准

断面编号	里程/m	底高程/m	备注
1号断面	0.0	0.0	真实存在的第一级水位断面
2号断面	200.0	50.0	虚拟断面
3号断面	400.0	100.0	虚拟断面
4号断面	600.0	150.0	虚拟断面
5号断面	800.0	200.0	最接近水位线的、真实存在的断面

在上述站点周边水系环境中, 1号断面、5号断面是真实存在的, 而 2号、3号、4号断面则是人为虚拟定义的。随着断面编号定义值的增大, 里程、底高程数值都表现出不断增大的数值状态, 前者的单位间隔为 200.0 m、后者的单位间隔为 50.0 m^[15-16]。

如果站点周边水系环境的覆盖范围相对较大, 那么断面组织的数值定义量也会随之出现一定程度的增大。利用

公式 (4), 推导水位数据采集表达式如下:

$$E = \sqrt{\frac{r_1}{\kappa_1} \cdot \frac{r_2}{\kappa_2} \cdot \dots \cdot \frac{r_n}{\kappa_n}} \times \frac{Y}{(\lambda e)^2} \quad (5)$$

式中, r_1, r_2, \dots, r_n 表示 n 个不重合的水位断面, n 表示断面组织数值定义量的最大值, $\kappa_1, \kappa_2, \dots, \kappa_n$ 分别表示与水位断面匹配的里程值定义项, \bar{e} 表示底高程定义项的平均值, λ 表示水位数据实时采集向量。由于人为虚拟断面并不真实存在于站点周边水系环境中, 所以该类型断面组织之间的里程值与底高程值有可能出现一定程度的偏差。

2.3 水位数据清洗

由于仪器条件、测量技术、外界条件等因素, 预测系统所测得的站点周边水位数据难免存在一定的质量问题, 而对于双向 LSTM 神经网络而言, 数据质量会对水位数据预测精度产生极大的影响, 因此对采集所得的原始水位数据进行清洗极为必要。如果双向 LSTM 神经网络在时间节点上无法观测到水位数值, 则有可能导致预测系统实际测量结果出现时间性缺失, 当主机元件必须对缺失数据进行采集时, 则会使站点周边水位预测结果中出现明显的缺失项^[17]。从宏观性角度来看, 时间性缺失属于一种常见的水位数据异常行为, 特别是在数据偏离长度较大时, 如果不能将这一类数据参量完全清洗出去, 则会导致水位记录装置浮标出现错误记录水位信息的情况。

对于站点周边水位数据的清洗参考如下表达式:

$$W = \exp\left[-\frac{\eta(\hat{q}A_0)^2}{E^2}\right] \quad (6)$$

式中, η 表示水位记录装置对于站点周边水位数据的预测效率, \hat{q} 表示基于双向 LSTM 神经网络模型所选取的水位数据处理特征, A_0 表示站点周边水系环境中的水位数据标准记录数值。为满足水位记录装置对于站点周边水位数据的准确监测需求, 在清洗水位采集数据时, 还应保证站点周边水系环境中至少存在 3 个完整的虚拟断面单元^[18]。

2.4 双向 LSTM 神经网络输入参数

构建一维水动力模型, 根据一维水动力模型获取影响站点周边水位预测结果的糙率, 确定流量与延时时间关系, 以上述参数作为双向 LSTM 神经网络的输入参数来训练模型进行站点周边水位预测。在训练过程中, 将糙率和流量与延时时间转化为特征向量, 并将其作为 LSTM 模型的输入数据, 同时将实际观测的周边水位作为目标值进行监督学习。

2.4.1 一维水动力模型的构建

在双向 LSTM 神经网络中, 只有依照水动力模型表达式, 才能得到符合区域性水系特征的水位值测量结果。一维水动力模型可以描述水体在空间和时间上的变化规律, 提供水流的基本参数, 如流量、水位、速度等。而双向 LSTM 神经网络则可以学习历史数据中的模式, 并预测未来的水位变化。一维水动力模型可以提供水流的基本物理参数和变化规律, 为双向 LSTM 神经网络提供可靠的输入数据。而双向 LSTM 神经网络则可以学习历史数据中的模

式, 并预测未来的水位变化, 提供精准的水位信息数值。

一维水动力模型描述了系统主机所预测到站点周边水位数据的数值分布关系, 所谓一维可以理解站点周边水系环境中的简单水位信息定义标准, 完成水位数据清洗后, 保证对一维水动力模型中的数据样本进行完整取样, 才能使水位记录装置所测得的水位信息符合水体实际分布情况^[19-20]。

规定 \vec{a} 表示站点周边水系环境中的水体径流量一维定义向量, 其计算式如下:

$$\vec{a} = W |\mu \times \bar{d}|^{-1/s} \quad (7)$$

式中, \bar{d} 表示水位断面内的水资源传输动力均值, μ 表示一维动力条件下的水体径流速率赋值参数, s 表示站点周边水系环境中的水体流量定义项。

联立公式 (6)、公式 (7), 可将基于双向 LSTM 神经网络的站点周边水系一维水动力模型表达式定义为:

$$D = \frac{\vec{a} \cdot W}{\sum_{v \rightarrow \infty} fhg^{-1}} \quad (8)$$

式中, v 表示站点周边水系环境中的实时水位标记参数, f 表示双向 LSTM 神经网络所测得的水量分布系数, h 表示相邻水位断面间的水流输送量, g 表示一维环境中的水位描述信息。在站点周边水系环境中, 双向 LSTM 神经网络只有在—维水动力模型的配合下, 才能测得准确的水位信息数值。

2.4.2 水系糙率计算

在一维水动力模型中, 影响站点周边水位预测结果的因素有很多, 如水体流速、流量、过水断面面积、水系糙率等等, 其中糙率指标对水位变化行为的影响最为关键。所谓糙率是指水流阻力对站点周边水位深度的影响, 作为一个综合性无量纲参数, 水系边界的表面越粗糙, 糙率指标的数值计算水平就越高; 反之, 水系边界的表面越光滑, 糙率指标的数值计算水平就越低^[21]。从宏观性角度来看, 水系糙率的计算结果受到站点周边水体流量特征的直接影 响, 应用双向 LSTM 神经网络预测水位信息时, 为保证测量结果的准确性, 还应保证在测量过程中站点周边水系内的水体流速始终保持相对稳定的数值状态^[22]。

站点周边水位预测系统对于水系糙率指标的计算参考公式 (9):

$$G = \bar{w}^2 \cdot \left(\frac{D}{\hat{\theta}_j} + \bar{H}\right) \quad (9)$$

式中, \bar{w} 表示站点周边水系环境中的无量纲性水体流速评级系数, $\hat{\theta}_j$ 表示水流阻力的数值特征, θ 表示水系边界表面的粗糙度定义参数, \bar{H} 表示单位预测周期内的水体流量特征。为保证系统主机对站点周边水位的准确预测能力, 在计算水系糙率指标时, 还应保证水流阻力受力方向与水系流动方向的一致性。

2.4.3 流量与延时时间关系确定

在基于双向 LSTM 神经网络的站点周边水位预测中, 流量与延时时间的关系对于预测模型的准确性和实用性起到重要作用。对于站点周边水位预测系统而言, 拟合水位

记录数据与原始水位数据必须参考流量与延时时间的数值关系。流量可以理解为站点周边水系环境中的水体实时输出量, 作为一项标量物理参数, 其数值水平越高, 就表示站点周边水系环境中的实时水流速度越快^[23]。延时时间是指径流水体由第一级水位断面传输至最接近水位线断面所需经历的时间, 在不考虑其他干扰条件的情况下, 延时时间越长就表示站点周边水系的水位深度值越大, 系统主机在预测水位信息时, 所需清洗的水位数据就越多^[24]。总而言之, 流量和延时时间是基于双向 LSTM 神经网络的站点周边水位预测中重要的输入变量。

设 \bar{M} 表示第一级水位断面、最接近水位线断面之间的水体流量特征, l 表示实时水流速度判定系数, \bar{N} 表示径流水体的延时时间特征, ϑ 表示水流方向定义系数, \bar{b} 表示系统主机中的水位记录信息处理参量。在上述物理量的支持下, 联立公式 (9), 推导流量与延时时间的数值表达式关系为:

$$K = \frac{\sqrt{\left| \frac{\bar{M}}{l} \right| \times \left| \frac{\bar{N}}{\vartheta} \right|}}{bG} \quad (10)$$

在双向 LSTM 神经网络中, 站点周边水位预测系统的运行需要各级主机部件的共同配合, 而出于预测精准性考虑, 在调节各级部件结构的运行状态时, 还应考虑水系糙率、一维水力模型等参量指标的实际取值情况。

2.5 双向 LSTM 神经网络训练结果

通过监测和准确预测水系糙率、流量与延时时间关系变量的变化, 可以更好地了解 and 预测周边地区的水位变化情况, 为水利管理、防洪减灾等提供科学依据。

使用训练好的模型对站点周边水位进行预测, 以清洗后的水位数据作为训练数据集对双向 LSTM 模型进行训练。对于每个训练样本, 将输入序列提供给模型, 并与相应的目标值进行比较以计算损失, 通过反向传播算法调整模型的权重。重复进行多次迭代, 直到模型的性能达到满意的水平, 模型训练输出为水位变化趋势, 计算公式如下:

$$Q = \sum_{\alpha=1}^{\beta} \sqrt{\omega_{\beta} \frac{K}{G}} \quad (11)$$

式中, ω_{β} 为模型权重, β 为迭代次数。根据双向 LSTM 神经网络训练结果, 可以获取水位变化趋势的准确预测结果, 为站点周边水位预测系统的决策提供支持。

3 实验分析

为验证基于双向 LSTM 神经网络的站点周边水位预测系统、基于 DWT-LSTM 的水位预测模型、抽水蓄能引水型水位监测系统在解决水位记录数据、原始水位数据之间拟合差值过大问题方面的应用能力, 设计如下对比实验。

3.1 实验原理

水位记录数据与原始水位数据之间的拟合差值过大, 是导致站点主机无法准确预测周边水系特点的主要原因。本次实验选用两台配置相同的监测设备进行实验, 如图 5 所示。其中, 1 号监测设备为完成调试的 JP-PH160 元件, 其监测所得数据为该水系环境中的原始水位数据; 2 号监测

设备为可输入预测程序的 UTi260A 元件, 分别将不同的系统软件程序输入 2 号监测设备中, 得到不同预测系统所测得的实时水位记录数据。

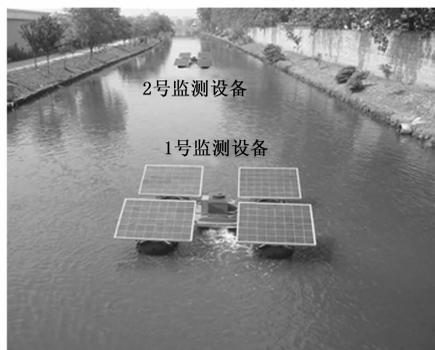


图 5 区域性水系环境中的水位信息监测

对于本次实验所选的水系区域而言, 5 月份、6 月份降水较为普遍, 且非降水时期的昼夜温度差值也相对较大, 所以水位信息的变化行为也就相对较为明显, 因此本次实验就选定这两个月作为具体实验周期。

本次实验的具体执行流程如下:

1) 为 1 号监测设备通电, 根据所得水位数据测量值, 整理该水系环境中的原始水位数据, 如图 6 及表 2 所示。

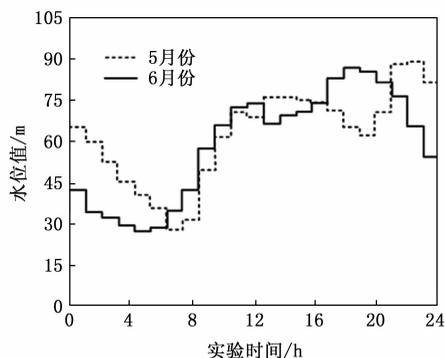


图 6 原始水位数据

表 2 原始水位数据记录结果

实验时间/h	5 月份	6 月份
0	66.7	43.9
4	45.0	29.8
8	31.9	44.0
12	68.1	74.5
16	74.9	74.9
20	68.3	81.6
24	82.0	52.7

2) 将基于双向 LSTM 神经网络的站点周边水位预测系统执行程序输入 2 号监测设备, 分别记录 5 月份、6 月份的水位数值, 所得结果为实验组变量。

3) 将基于 DWT-LSTM 的水位预测模型执行程序输入

2号监测设备,分别记录5月份、6月份的水位数值,所得结果为对照(A)组变量。

4)将抽水蓄能引水型水位监测系统执行程序输入2号监测设备,分别记录5月份、6月份的水位数值,所得结果为对照(B)组变量。

5)统计水位记录数据与原始水位数据之间的差值情况,总结实验规律。

3.2 数据处理

下表记录了实验组、对照(A)组、对照(B)组水位记录数据的具体实验情况。

表3 水位记录数据实验结果

实验时间/ h	实验组/m		对照(A)组/m		对照(B)组/m	
	5月份	6月份	5月份	6月份	5月份	6月份
0	66.7	43.9	65.1	42.1	70.0	46.4
4	45.0	29.8	47.2	30.6	41.7	31.5
8	31.9	44.0	30.8	42.5	30.1	47.2
12	68.1	74.5	65.4	73.2	65.2	77.3
16	74.9	74.9	70.3	75.4	77.8	78.0
20	68.3	81.6	69.0	80.9	65.3	80.6
24	82.0	52.7	81.5	51.3	85.6	50.1

将表3结果与表2的原始水位数据记录结果对比可知,实验组5月份、6月份水位记录数据实验结果与原始水位数据之间的差值始终为零,根据公式:

$$\omega = \frac{Z' - Z_0}{Z_0} \times 100\% \quad (11)$$

可知,在水位记录数据与原始水位数据之间差值等于零(即 $Z' - Z_0 = 0$)的情况下,二者之间的拟合误差也为零。公式(11)中, ω 表示水位记录数据与原始水位数据的拟合误差, Z' 表示水位记录数据, Z_0 表示原始水位数据。

对照表2的原始水位数据可知,对照(A)组5月份的水位差值为1.9m、6月份的水位差值为1.1m,整个实验过程中,对照(A)组水位差均值为1.5m,联立原始水位数据均值,对对照(A)组水位记录数据与原始水位数据的拟合误差进行计算,结果为2.5%,高于实验组数值水平。对照(B)组5月份的水位差值为3.0m、6月份的水位差值为2.4m,整个实验过程中,对照(B)组水位差均值为2.7m,联立原始水位数据均值,对对照(B)组水位记录数据与原始水位数据的拟合误差进行计算,结果为4.5%,也高于实验组数值水平。

3.3 实验结论

综上所述本次实验结论为:

1)基于DWT-LSTM的水位预测模型、抽水蓄能引水型水位监测系统的应用,不足以解决水位记录数据与原始水位数据之间差值较大的问题,故而并不能保证站点主机对周边水系特点的准确预测能力。

2)应用基于双向LSTM神经网络的站点周边水位预测系统,实现了水位记录数据与原始水位数据之间的无误差

拟合,符合保障站点主机对周边水系特点准确预测能力的实际应用需求。

4 结束语

设计基于双向LSTM神经网络的站点周边水位预测系统,从硬件方面着手,联合周边水系查询体系、水位记录装置,选定双向LSTM神经网络的基础运行参数,又通过完善神经网络布局模型的方式,定义具体的解码器闭环结构。对于采集所得的水位数据,双向LSTM神经网络进行了针对性清洗,在一维水动力模型的支持下,计算水系糙率指标的具体取值范围,从而确定流量与延时时间的数值映射关系。相较于基于DWT-LSTM的水位预测模型、抽水蓄能引水型水位监测系统,在双向LSTM神经网络模型的作用下,站点周边水位预测系统的应用解决了水位记录数据与原始水位数据之间差值较大的问题,对于站点主机而言,其在准确预测周边水系特点方面的应用能力得到了有效保障。

参考文献:

- [1] 胡腾飞,施勇,毛劲乔,等.基于结构-参数同步优化的河湖水位模型及应用[J].排灌机械工程学报,2022,40(5):461-466.
- [2] 倪汉杰,蒋仲廉,初秀民,等.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.
- [3] 冯凌云,梁彦.抽水蓄能电站引水隧洞水位监测系统的开发与应用[J].水电能源科学,2021,39(3):95-98.
- [4] 况华,何鑫,何冕,等.基于双向长短期记忆神经网络的配网电压异常数据检测[J].科学技术与工程,2021,21(24):10291-10297.
- [5] 查阳,王迪芳,曹承进,等.太浦河金泽水源地大莲湖示范区水系水环境状况调查研究[J].华东师范大学学报(自然科学版),2021,218(4):64-71.
- [6] 刘栋梁,李海兵,王平,等.南海北部盆地新生代物源对周边主要河流演化的响应[J].地质学报,2022,96(8):2761-2774.
- [7] 王晓燕,李文鹏,安永会,等.抽水试验中不同位置自动水位计响应数据应用分析[J].水文地质工程地质,2022,49(3):57-64.
- [8] 张延泰,孙建红,侯斌,等.分离式飞机应急数据记录跟踪系统设计与试验[J].北京航空航天大学学报,2021,47(11):2322-2330.
- [9] 张超轶,陈媛,张聚伟.融合术语信息的神经机器翻译参数初始化研究[J].河南科技大学学报(自然科学版),2022,43(4):61-66.
- [10] 潘学萍,戚相威,梁伟,等.综合模型聚合和参数辨识的风电场多机等值及参数整体辨识[J].电力自动化设备,2022,42(1):124-132.
- [11] 杨彦杰,董哲,姚芳,等.基于1D-CNN-LSTM混合神经网络模型的双桥并联磁功率单元故障诊断[J].电网技术,2021,45(5):2025-2032.

(下转第33页)