

基于 LSTM 模型的北威克试验站 小流域实时径流预报

李 博¹, 降亚楠^{1,2}, 张 特¹, 姜田亮¹

(1. 西北农林科技大学 水利与建筑工程学院, 陕西 杨凌 712100;

2. 西北农林科技大学 旱区农业水土工程教育部重点实验室, 陕西 杨凌 712100)

摘 要: 为探讨深度学习方法在小流域实时精细化径流预报中的适用性, 建立了基于长短时记忆网络 (LSTM) 的英格兰北威克试验站小流域实时径流预报模型。借助深度学习框架 Tensorflow, 采用 LSTM 识别输入特征及输入输出间的复杂非线性关系, 将逐时段流域径流、前期降雨及气温三要素作为输入, 分析了多种输入组合和多个时间步长的实时径流预报效果。结果表明: 基于 LSTM 的模型在各子流域的径流预报效果较好, 训练期和验证期的纳什系数均高于 0.90, 该模型可用于研究区的实时径流预报, 可为流域防洪调度提供技术支撑。

关键词: 长短时记忆网络; 实时径流预报; 北威克试验站; 小流域

中图分类号: P338

文献标识码: A

文章编号: 1672—1144(2022)03—0217—07

Runoff Nowcasting of Small Watershed in the North Wyke Station Based on LSTM Model

LI Bo¹, JIANG Yanan^{1,2}, ZHANG Te¹, JIANG Tianliang¹

(1. College of Water Resources and Architectural Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China;

2. Key Laboratory of Agriculture Soil and Water Engineering in Arid and Semiarid of Ministry of Education,
Northwest A&F University, Yangling, Shaanxi 712100, China)

Abstract: In order to explore the applicability of deep learning method in small watershed runoff nowcasting, a model was developed and tested based on long short-term memory (LSTM) network at the North Wyke Farm Platform in England. LSTM developed based on Tensorflow was adopted to identify the inputs and the complex nonlinear relationship between input variables and output variables. The effects of multiple input combinations and multiple time steps are analyzed by taking the three elements, i. e., early runoff, rainfall, and air temperature. The results showed that the LSTM performed good in small watershed, and the Nash efficient coefficient in the training and validation period were both higher than 0.90.

Keywords: long short-term memory network; runoff nowcasting; North Wyke Farm; small watershed

实时径流预报在防洪抗旱及水资源精细化管理中发挥着重要作用, 但由于受到流域内天气条件、地形地貌、植物覆盖、降雨特征、地理位置等各种因素的共同影响, 径流呈现高度的非线性, 实时径流预报在水文过程模拟中始终是一个难题^[1-3]。实时径流

预报方法包含过程驱动方法(具有物理机制)和数据驱动方法^[4]。过程驱动方法的基础是含有物理过程信息的偏微分方程和线性方程组^[5-6]。但实时径流预报对模型构建速度和求解运行效率要求高, 所需的数据量大且建模计算复杂, 因此, 通过过程驱

收稿日期: 2022-01-21

修稿日期: 2022-02-22

基金项目: 国家重点研发计划(2016YFC0400305; 2016YFC0401306); 国家自然科学基金项目(51409219)

作者简介: 李 博(1997—), 男(土家族), 硕士研究生, 研究方向为水文学及水资源。E-mail: yclb1997@foxmail.com

通讯作者: 降亚楠(1984—), 男, 博士, 副教授, 主要从事水文学及水资源研究方面的工作。E-mail: yananjiang@nwafu.edu.cn

动模型进行实时径流预报面临诸多难题^[7]。以数据驱动为主导的方法可以进行大量实时数据分析处理,在高时空分辨率水文要素量测数据增加的背景下,具有不可忽视的优点,其本质是一种统计方法,更着重于实测水文资料中前期影响因素与径流间的输入输出关系,而忽略了因素间明确的因果关系^[8]。大量研究表明,可以通过选取机器学习中的神经网络(ANN)和支持向量机(SVM)等模型,挖掘径流序列中隐藏的非线性特征,进而达到改进预测结果的目的^[9-10]。

深度学习作为机器学习中的前沿技术,其显著特点是在神经网络架构中设置多层神经元,在处理复杂映射方面拥有更优性能^[11]。近年来,研究人员已经采用 LSTM 进行径流时间序列分析和预报,表明 LSTM 在径流预报方面具有更出色的性能。叶陈雷等利用 LSTM 模型对社区尺度的降雨径流关系进行模拟,基于不同的降雨情景和 SWMM 模拟值生成的数据集,评估了 LSTM 模型的模拟效果,结果表明 LSTM 模型对降雨径流的模拟性能与 SWMM 模型基本相当^[12]。Yin 等^[13]运用基于 LSTM 和 S2S 的多状态向量序列到序列(LSTM-MSV-S2S)降雨径流模型,选取 CAMELS 数据集上 673 个流域的日气象数据和日径流观测值进行测试,在预报期为 7 d 的径流预报方面取得了不错的性能表现。上述研究成果表明深度学习模型在不同时间尺度预测中具备优势。在目前自动化水文监测设备不断完善的情况下,在小流域上获得观测尺度更精细的径流气象数据已日渐成熟,之前较多研究关注小时及更大尺度的径流预报,目前尚无针对小流域在更精细的时间尺度上,深入探讨 LSTM 实时径流预报性能方面的研究^[14]。

鉴于此,本文运用 LSTM 原理建立了英格兰北威克试验站小流域分钟尺度的实时径流预报模型,将逐时段径流、前期降雨及气温三个要素作为输入进行实时径流预报,并通过模拟值和实测值的对比分析,评估模型的预报性能,以期能为流域实时径流预报提供技术支撑。

1 研究区概况与数据获取

1.1 研究区概况

研究区域位于英格兰西南部(50°46′10″N, 3°54′05″W)的北威克试验站(the North Wyke Farm Platform, NWAFP),是为可持续草地畜牧业系统研

究建立的标准农场试验站,如图 1 所示。北威克试验站海拔为 120 m ~ 180 m,1985 年—2015 期间年平均气温为 6.8℃ ~ 13.4℃,年平均降水量为 1 033 mm,土壤质地构成主要包括石质壤土(约 36% 壤土)以及石质黏土(约 60% 黏土)且底层土壤透水性较弱,流域降雨期间大部分雨水通过试验站地表排水系统排出^[15]。该试验站由三个独立的小试验站组成,每个小试验站的面积为 21 hm²,且每个小试验站包含五个子集水区。该平台定期对 15 个子集水区内的径流、降雨、气温和相对湿度等气象要素按 15 min 时间精度进行定期监测,可为实时径流预报提供充足的数据。




图 1 北威克试验站地理位置及子集水区分布图

1.2 数据收集

图 1 所示 15 个子集水区域在水文联系上相互独立,经由沟渠引导径流至组合流量仪表水槽,北威克试验站自 2012 年 10 月起以 15 min 时间频率监测子流域降雨、土壤湿度、气温、径流及其化学成分等指标。由于第 10 至第 15 子流域缺失前期降雨径流资料,故研究区选定为其余资料完善的 9 个子流域(图 1 标签分别为 1、2、4、6、7、8、9、11、12)。英格兰西南部秋冬季为雨季,降雨径流关联程度高,为降低模型计算成本且确保训练数据间的水文联系,选择 4 至 5 个月作为训练周期。故本文选取该站 2017 年 10 月—2018 年 3 月的流域前期降雨、流域气温、流域径流和流域相对湿度的 15 min 数据集作为模型训练资料^[16-17]。样本总数为 15 552,其中训练周期样本数占比为 80%,共计 12 442,测试周期样本数占比为 20%,共计 3 110。

2 基于 LSTM 的实时径流预报

2.1 LSTM 模型基本原理

LSTM 属于循环神经网络,通过模型结构具备的输入门、遗忘门和输出门能有效解决梯度问题,在解决时间序列相关的回归问题中表现出更优的性能。LSTM 最早由 Hochreiter 等^[16]提出,之后被 Graves 等^[17]进一步改善。

LSTM 记忆单元的内部结构如图 2 所示。 t 记忆单元的输入信息包含输入变量 X_t 、隐藏层变量 h_{t-1} 和记忆单元变量 C_{t-1} 。模型经由三种门结构,通过梯度下降算法和对误差的反向传播算法调整网络结构的权重与偏置参数。输出包括:输出变量 h_t 和记忆单元变量 C_t 。各部分结构如下^[18]:

遗忘门 f_t : 决定记忆单元变量 C_{t-1} 的舍弃状态。




图2 长短记忆模型记忆单元结构示意图

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

输入门 i_t : 决定 X_t 以何种比例输入到 C_t 中。

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

候选门 $\tilde{C}_t$: 计算当前输入的单元状态。

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

至此, t 记忆单元的组成包括遗忘门留存下的信息和输入门新输入的信息。

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (4)$$

输出门 O_t : 计算当前时刻信息输出程度。

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = O_t \times \tanh(C_t) \quad (6)$$

h_t 传递到模型的输出层以后经过计算得到在 t 时刻的最后输出信息为 y_t 。

$$y_t = w_d \cdot h_t + b_d \quad (7)$$

式中: f_t 表示遗忘门信息, i_t 表示输入门信息, O_t 表示输出门信息, C_t 表示记忆单元变量, C_{t-1} 表示记忆单元变量, $\tilde{C}_t$ 表示输入的单元状态; $\sigma(\cdot)$ 表示 sigmoid

激活函数; $\tanh$ 是双曲正切激活函数; h_{t-1} 表示隐藏层变量, h_t 表示隐藏层变量, X_t 表示输入变量, W_f 、 W_i 、 W_c 、 W_o 表示权重矩阵; b_f 、 b_i 、 b_c 、 b_o 表示偏置向量。

2.2 模型构建

2.2.1 网络结构

本文采用五层 LSTM 循环神经网络建模, 分别为输入层、双隐含层、丢弃层以及全连接输出层, 输入层神经元个数为 200, 隐含层神经元个数为 32, 输出层神经元个数为 1。第一层输入流域相关气象数据, 第二及第三隐含层决定输入信息的遗忘与更新, 通过反向传播算法寻求最优模型参数进行模拟。第四层为一层丢弃层, 设定丢弃率为 50%^[19], 即随机性地屏蔽半数神经元。第五层为全连接输出层, 用于独立输出模拟的流域径流序列。

2.2.2 参数率定

LSTM 网络参数主要有两种, 一种为网络内部隐藏神经元和输入输出层间的权重与偏置, 通过反向传播算法自动调整和更新参数; 另一种为超参数, 神经网络模型中包含有多种超参数, 例如学习率、正则化参数、神经网络层数、隐藏层神经元数目、学习循环次数、激活函数等, 在机器学习中超参数不能直接从标准模型培训过程的数据中学习, 需要在开始训练模型之前预先设置超参数值。通过模型参数率定, 达成优化超参数目的, 进一步提升模型模拟的精度。为衡量优化算法在独立数据集上的性能, 在选择最优超参数过程中面临模型选择和超参数优化等问题, 本文采用均方根误差 RMSE 作为损失函数对模型超参数进行优化。

将初始学习率设置为 0.01, 每循环 10 000 次学习率衰减为前一刻的 90%, 达到迭代更新学习率目的。训练次数是指神经网络使用训练集中全部样本的学习次数, 若训练时间过长则易出现过拟合现象, 即模型仅对训练数据进行特征提取而泛化性能较差。反之训练次数不足则会出现欠拟合问题, 无法充分挖掘数据的共有特征。本文设置初始训练次数为 500 次, 其后依次减少训练次数, 观察到理想的拟合结果稳定在 200 次后, 因此将后续训练次数都设置为 200 次。其余超参数则通过经验试错法进行优化, 采取的设置场景和超参数选取情况如表 1 所示。

表 1 LSTM 网络超参数选择情况

参数类型	参数名称	调参方式	实验设置
全局超参数	隐藏层数		2
	神经元个数		32
	输入数据包		32
	预测窗口	经验调参	{1,2,3,4,5,10,15,20,30}
	丢弃率		0.5
训练超参数	学习率		0.01
	迭代次数		200

2.2.3 数据预处理

考虑到降雨量、气温、相对湿度等气象数据具有不同量纲和量纲单位,为消除指标之间量纲影响以解决数据指标之间的可比性,将数据归一化到 0 和 1 之间:

$$x^* = \frac{x - \min_x}{\max_x - \min_x} \tag{8}$$

式中: x 为原始输入数据; $\min_x$ 和 $\max_x$ 为原始输入数据中对应的最小值和最大值。

使用下列公式将模型模拟的径流量归一化值转换为径流量实际值:

$$x = x^* (\max_x - \min_x) + \min_x \tag{9}$$

2.2.4 输入因子选取

从研究资料中选取 2013 年 10 月 1 日—2014 年 2 月 1 日为模型训练期,2014 年 2 月 1 日—2014 年 3 月 11 日为模型验证期。以往的研究主要以前期径流作为模型输入变量,为进一步提高模型预测精度,本次研究从诸如降雨、气温、相对湿度等气象要素中选取 4 类相关因素来训练径流预报模型,即流域前期径流量、流域前期降雨、流域气温和相对湿度。

可选择这 4 类因素中的一种或数种作为输入因子预报流域径流。根据有可能的输入因子组合,设置了 7 组输入方案,方案 1 仅采用一种输入因子,属于第 I 类方案;方案 2—方案 4 有 2 种输入因子,属于第 II 类方案;方案 5—方案 7 有 3 种输入因子,属于第 III 类方案。每种输入方案的预见期相同且采用统一长度预测窗口,不同输入因子情况依此类推具体情况见表 2。

2.2.5 预测窗口设定

LSTM 长短记忆模型的窗口长度对模型预测效果有重要影响,在本文中分析了不同窗口长短对预测效果的影响试图寻找出最优参数。以运算精度和数据集容量作为参考,设置了 9 组预测窗口,长度分别为 1、2、3、4、5、10、15、20、30 个单位步长,即 15

min(I)、30 min(II)、45 min(III)、1.25 h(IV)、2.50 h(V)、3.75 h(VI)、5.00 h(VII)、7.50 h(VIII)、9.00 h(IX),从中筛选出预测效果最优的窗口作为最终预测窗口长度。

表 2 径流预报模型不同输入方案

预测方案	模型输入变量			
	前期径流	流域前期降雨	流域气温	流域相对湿度
方案 1	✓	—	—	—
方案 2	✓	✓	—	—
方案 3	✓	—	✓	—
方案 4	✓	—	—	✓
方案 5	✓	✓	✓	—
方案 6	✓	✓	—	✓
方案 7	✓	—	✓	✓

2.3 模型评价指标

LSTM 通过训练样本得到优化模型,再用该模型将输入映射为输出进行预测,模型的预测效果采用统计指标进行量化,本文选用纳什效率系数和均方根误差对模型精度进行评估,其计算公式分别为:

$$NSE = 1 - \frac{\sum_{i=1}^n (y_i - y_i')^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \tag{10}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - y_i')^2}{n}} \tag{11}$$

式中: y_i' 为模拟值, y_i 为观测值, $\bar{y}$ 为观测数据的平均值, n 为序列总长度。RMSE 数值越小表明观测序列与模拟序列越接近,定量误差越小;NSE 越接近 1 表明观测序列与模拟序列在径流预报过程中吻合程度越高。一般情况下 NSE 大于(0.50 ~ 0.65) 这一阈值区间时,即可认为网络模型预测效果可以接受^[20]。

3 研究结果

3.1 模型参数优选

3.1.1 输入因子对模型预测效果的影响

图 3 为七种输入方案下依次模拟 50 次后该流域径流预报精度指标。由观察可知,七种输入方案的 NSE 均处于 0.80 ~ 0.98 范围,RMSE 处于 0.000 ~ 0.035 m³/s 范围,预测精度较好。方案 1 使用径流数据作为单一类型输入变量,模拟期和验证期 NSE 稳定在 0.97 附近,验证期相较于模拟期 RMSE 有较小幅度削减,但箱体分布相对离散,上下限差距较大。方案 2—方案 4 皆为双因子类型输入变量,

三类输入方案处于验证期的 NSE 较模拟期有显著程度削减,且验证期的 RMSE 均有不同程度上升,验证期预测精度指标总体弱于模拟期。方案 5—方案 7 为三因子类型输入变量,径流预报精度较双因子方案均有所提高且 RMSE 略有降低。以上三类方案中验证期的 NSE、RMSE 与模拟期相比维持稳定,无明显幅度波动,体现出三输入因子训练模型具备良

好的稳定性与泛化性能。其中方案 5 对应的输入因子为流域径流、流域前期降雨和流域气温,验证期和模拟期的 NSE 均为三类方案中最高精度指标,验证期和模拟期 RMSE 均为数值最低,且分布相对集中离散化程度低,上下限差距更小,综合考虑模型的模拟性能和计算效率,选择方案五作为最优的径流预报输入变量。




图 3 不同输入方案下模拟指标

3.1.2 输入窗口对模型预测效果的影响

选用 9 种不同长度的窗口构建模型,预测结果如图 4 所示。在预测窗口长度增加初期,模拟期和验证期 RMSE 下降较迅速,模拟期 RMSE 在预测窗口为 4 个单位步长时达到最小值,验证期 RMSE 在预测窗口长度为 3 个单位步长时达到最小值。当预测窗口继续增大至方案 7 所对应的 15 个单位步长时,模拟期和验证期 RMSE 均有不同程度增大,存在过拟合特征。当预测窗口超过 15 个单位步长后,模拟期与验证期的 RMSE 在小幅度波动的情况下趋近于稳定,继续增加预测窗口长度对于模型模拟效果并无显著增益。类似的特征也在 NSE 的变化过程中有所体现,在模拟期内当预测窗口长度小于 4 个单位步长时,随着预测窗口增加 NSE 也相应增加。在大于 4 个单位步长时,窗口长度增大会导致 NSE 继续降低。当窗口超过 15 个单位步长后,NSE 短暂上升,之后转为小幅度下降并逐渐趋于稳定。在验证期内当预测窗口小于 3 个单位步长时,模型模拟

效果随窗口长度增加而持续提升。窗口长度处于 4 个单位步长及以上范围,其后续对应变化特征与模拟期类似。在综合考虑计算效率和预测效果的前提下,方案 3 与方案 4 相比处于验证期的 NSE 更高, RMSE 更低,箱体数据分布集中且上下限差距更小,模型预测效果更优,在该预测模型中使用 3 个单位步长的预测窗口较为合理。

3.2 模型性能评估

在对模型各项参数进行调整和完善后,对模型预测性能指标进行评估。图 5 为径流预报模型在完整时间序列中不同子流域上预测结果与实测值的比较。由图观察得知:各子流域完整时间序列的 NSE 均在 0.970 左右,仅 C1 流域相对较低为 0.916,表明模型在径流预报方面的良好性能。C1 子流域在训练期与验证期散点分布与 45°直线偏离略大,其他子流域散点分布均趋近于 45°直线且于两侧均匀分布,表明模型在训练期和验证期均能有效捕捉各子流域的输入要素与径流的相关关系。将 C7 子流




图 4 不同输入窗口长度下模拟指标




图 5 各子流域完整时间序列径流预报结果

域预测结果作为代表进行分析(见图6),可以看出整体预测结果与实测值吻合较好,模型在非汛期及峰前峰后时刻均能较好地预测实测序列,但对峰值的预测效果略差,模型对于峰值预测偏低。




图6 C7子流域径流预报模型结果

4 结论与讨论

本文运用LSTM原理构建了英格兰南部北威克试验站小流域分钟尺度的实时径流预报模型,并采用NSE和RMSE两个评价标准定量评价预报模型在各子流域的性能。主要结论如下:

(1) 长短时记忆神经网络(LSTM)模型可以用于小流域的实时径流预报,且具备良好的模拟性能和预报能力,多个小区流域模型的NSE均可达到0.95左右。

(2) 模型输入及预测窗口长度的选择对模型精度和稳定性有较大影响,多气象数据输入的LSTM模型比单一气象数据输入的预报精度更高,且在多个输入情况下选取适当窗口长度的模型计算量较低。在北威克试验站流域的径流预报模型中选择以前期流域径流、流域降雨及流域气温作为输入因子,以三个单位时间步长(即45 min)作为预测窗口时模型预报效果最佳。

LSTM模型在北威克试验站流域径流预报中表现良好,主要有以下两方面原因:(1)该模型相比于其他机器学习模型,性能更加优越,对于长期序列更加敏感;(2)此外,本文研究区面积小、环境湿润,流域水文条件总体保持平稳。目前模型的缺陷在于对径流极值的预报效果较差,有待进一步采取实时校正等方法修复预报结果达到提高精度的目的。本文研究结果可为小流域实时径流预报模型的构建提供参考依据,今后可考虑持续完善影响因素和参数选择并采用多种模型耦合方式,以达到模型间优势互补

补进而提高预测效果和泛化能力。

参考文献:

- [1] Wang W C, Chau K W. A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series[J]. Journal of Hydrology, 2009,374(3):294-306.
- [2] 康燕楠,降亚楠,苏振辉. 基于NSGA-III和FloPy的灌区水资源多目标模拟优化模型[J]. 水利与建筑工程学报,2021,19(3):17-23.
- [3] 李继清,王爽,段志鹏. 基于ESMD-BP神经网络组合模型的中长期径流预报[J]. 应用基础与工程科学学报,2020,28(4):817-832.
- [4] Yuan X H, Chen C, Lei X H, et al. Monthly runoff forecasting based on LSTM-ALO model[J]. Stochastic Environmental Research and Risk Assessment, 2018,32(1):2199-2212.
- [5] Bittelli M, Tomei F, Pistocchi A, et al. Development and testing of a physically based three-dimensional model of surface and subsurface hydrology[J]. Advances in Water Resources, 2010,33(1):106-122.
- [6] Partington D, Brunner P, Simmons C T. Evaluation of outputs from automated baseflow separation methods against simulated baseflow from a physically based surface water-groundwater flow model[J]. Journal of Hydrology, 2012,458/459:28-39.
- [7] 李琳琳,岳春芳,任磊,等. 基于小波分解的径向基神经网络径流预测研究[J]. 水利与建筑工程学报,2014,12(4):200-203.
- [8] 胡庆芳,曹士坦,杨辉斌,等. 汉江流域安康站日径流预测的LSTM模型初步研究[J]. 地理科学进展,2020,39(4):636-642.
- [9] 杨人豪,杨庆媛,曾黎,等. 基于BP-ANN模型的农村土地生态安全评价及影响因素分析——以重庆市丰都县为例[J]. 水土保持研究,2017,24(3):206-213.
- [10] 王彤彤,翟军海,何欢,等. BP神经网络和SVM模型对施加生物炭土壤水分预测的适用性[J]. 水土保持研究,2017,24(3):86-91.
- [11] Chen L, Wu C W. A note on the expressive power of deep rectified linear unit networks in high-dimensional spaces[J]. Mathematical Methods in the Applied Sciences, 2019,42(9):147-161.
- [12] Wang Q R, Huang J, Liu R M, et al. Sequence-based statistical downscaling and its application to hydrologic simulations based on machine learning and big data[J]. Journal of Hydrology, 2020,586:124875.

(下转第236页)

- 湖生态流量确定工作方案的通知:办资管[2020]151号[A]. 2020-07-24.
- [20] 水利部办公厅. 水利部办公厅关于做好 2021 年重点河湖生态流量确定与保护工作的通知:办资管[2021]155 号[A]. 2021-05-19.
- [21] 贵州省水利厅. 贵州省水资源保护条例[A]. 2021-10-22.
- [22] 夏 豪,陈国柱,欧祖宏. 贵州省水利建设生态建设石漠化治理综合规划对全省水文情势的影响研究[J]. 贵州水力发电,2012,26(2):25-27.
- [23] 陈国柱,杨 杰,赵再兴. 水电工程生态流量实时监测技术发展的思考[J]. 环境影响评价,2017,39(6):6-8,38.
- [24] 贵州省人民政府. 省人民政府关于印发贵州省水利建设生态建设石漠化治理综合规划的通知:黔府发[2011]21 号[A]. 2011-07-10.
- [25] 国家环境保护总局办公厅. 水电水利建设项目河道生态用水、低温水和过鱼设施环境影响评价技术指南(试行):环评函[2006]4 号[A]. 2006-01-16.
- [26] 建设项目水资源论证导则:GB/T 35580—2017[S]. 北京:中国标准出版社,2017.
- [27] 河湖生态需水评估导则(试行):SL/Z 479—2010[S]. 北京:中国水利水电出版社,2010.
- [28] 李治业,陈 康,周 洲,等. 一种混凝土坝独立运行的生态流量管结构:中国,2020213778430. 2[P]. 2021-03-23.
- [29] 司法部.《中华人民共和国长江保护法》[EB/OL]. [2020-12-26]. http://www.chinalaw.gov.cn/Department/content/2020-12/27/592_3262808.html.
- [30] 严茂强,卢 兴,印小军,等. 生态流量在线监测系统及在水电站的应用[J]. 四川水利,2020(6):146-148.
- [31] 中华人民共和国中央人民政府.《水利部 生态环境部关于加强长江经济带小水电站生态流量监管的通知》(水电[2019]241 号)[EB/OL]. [2020] http://www.gov.cn/gongbao/content/2020/content_5471453.htm.
- [32] 贵州省水利厅. 贵州省强化生态流量监管全面迈向新阶段[EB/OL]. [2020-12-31]. http://mwr.guizhou.gov.cn/slxw/tbtj/202012/t20201231_65897471.html.

(上接第 223 页)

- [13] Yin H L, Zhang X W, Wang F D, et al. Rainfall-runoff modeling using LSTM-based multi-state-vector sequence-to-sequence model[J]. Journal of Hydrology, 2021, 598:126378.
- [14] 姜淞川,陆建忠,陈晓玲,等. 基于 LSTM 网络鄱阳湖抚河流域径流模拟研究[J]. 华中师范大学学报(自然科学版),2020,54(1):128-139.
- [15] Pulley S, Collins A L. Field-based determination of controls on runoff and fine sediment generation from lowland grazing livestock fields[J]. Journal of Environ Manage, 2019,249:109365.
- [16] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural computation, 1997,9(8):1735-1780.
- [17] Graves A, Schmidhuber J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures[J]. Neural Networks: The Official Journal of the International Neural Network Society, 2005, 18(5/6):602-610.
- [18] Gauch M, Kratzert F, Klotz D, et al. Rainfall-runoff prediction at multiple timescales with a single long short-term memory network[J]. Journal of Hydrology, 2020, 141:103622.
- [19] Guo B S, Hu J W, Wu W W, et al. The tabu-genetic algorithm: a novel method for hyper-parameter optimization of learning algorithms[J]. Electronics, 2019, 8: 579.
- [20] 陈昊荣,金 生. 基于 SWAT 模型的汉江流域径流模拟[J]. 水利与建筑工程学报,2020,18(1):245-250.