

汉江流域安康站日径流预测的 LSTM模型初步研究

胡庆芳¹, 曹士圻¹, 杨辉斌^{1,2}, 王银堂¹, 李伶俐¹, 王立辉²

(1. 南京水利科学研究院水文水资源与水利工程科学国家重点实验室, 南京 210029;

2. 福州大学水利水电与港口工程系, 福州 350116)

摘要: 论文基于2003—2014年水文资料, 采用长短期记忆神经网络(Long-Short Term Memory, LSTM), 构建了汉江上游安康站日径流预测模型, 评价了不同输入条件下日径流预测的精度。结果表明: 当预见期为1 d时, 在仅以安康站前期日径流量作为输入的条件下, LSTM模型在训练期和检验期的效率系数分别达到0.68和0.74; 如再将流域前期面雨量和上游石泉站前期日径流量加入LSTM网络作为输入变量, 安康站日径流量预测效果将更好, 训练期和检验期的效率系数最高可达到0.83和0.84, 均方根误差也有显著削减, 且对主要洪峰流量的预测能力也有一定提高。此外, LSTM可以有效避免过拟合等问题, 具有较好的泛化性能。但当预见期从1 d延长至2、3 d时, LSTM的预测精度显著降低。

关键词: 长短期记忆神经网络; 日径流预测; 汉江流域; 安康站

河川径流预报是水文水资源研究领域的最基本的科学问题, 也是最基本的业务性工作之一。及时准确地预测不同时间尺度上河川径流的动态变化可以深化对流域水文过程的科学认识, 对于强化水资源合理利用与调配、提升防洪减灾能力具有重要意义。经过长期发展, 河川径流预测途径主要有3种: 一是数据驱动方法, 这类方法不着重于描述具体的水文物理机制, 而是依赖于历史观测资料, 通过建立相关前期影响因素与当前径流要素之间的输入-输出关系进行预测; 二是概念性或集总式水文模型, 这类方法是建立在对流域产汇流机理与过程的概化性、不完备描述的基础上; 三是物理性水文模型, 基于数学物理方程, 多以空间离散方式详细描述径流形成与转化过程。

数据驱动模型是发展较早的径流预测模型。但随着20世纪60年代以来流域水文模型的蓬勃发

展, 以及人类活动对径流过程的影响越来越明显, 数据驱动模型因其物理机制不足的缺点, 一度备受质疑。但随着水文数据和观测资料的日益丰富和各种数据挖掘算法的大量涌现, 人工智能与水文水资源学科的交叉性不断增强, 同时无论是概念性还是物理性水文模型的发展都遇到一定瓶颈, 且水文模型径流预报需要建立在降水预报信息的基础上, 因此, 近年数据驱动模型重新受到重视, 国内外能够更加客观看待数据挖掘方法的优点和不足。如Liang等^[1]将多分辨率学习范例神经网络应用于长期月径流预报, 仅用到历史径流数据作为输入。Kurtulus等^[2]基于人工神经网络和模糊理论建立了法国La Rochefoucauld喀斯特系统日径流预测模型, 能够较为准确地预测洪水峰值。Tiwari等^[3]将人工神经网络与小波分析、自助采样等方法相结合, 构建了WBANN日径流预报模型。赵钢铁等^[4]提出了

收稿日期: 2019-11-04; 修订日期: 2020-02-20。

基金项目: 国家重点研发计划项目(2016YFC0400902); 国家自然科学基金项目(51479118)。[Foundation: National Key Research and Development Program of China, No. 2016YFC0400902; National Natural Science Foundation of China, No. 51479118.]

第一作者简介: 胡庆芳(1981—), 男, 博士、高工, 研究方向为水文预测预报、水文遥感和水资源规划。

E-mail: hqf_work@163.com

引用格式: 胡庆芳, 曹士圻, 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. [Hu Qingfang, Cao Shiyi, Yang Huibin, et al. Daily runoff prediction using LSTM at the Ankang Station, Hanjiang River. Progress in Geography, 2020, 39(4): 636-642.] DOI: 10.18306/dlkxjz.2020.04.010

基于互信息选择预报因子的方法并应用于径流预测的神经网络模型中,对方法的有效性作了验证。综合各类数据驱动方法,人工神经网络在径流预测中的应用较为广泛^[5-6],取得了不错效果。

2012年以来,一种具有深度学习的循环型神经网络——LSTM(Long-Short Term Memory)逐渐应用于水文预测领域^[7-8]。如 Kratzert 等^[9]基于 CAM-ELS 数据集使用 LSTM 模型对 241 个水文流域进行降雨径流测试,结果表明 LSTM 能够通过气象观测数据预测径流,其性能可与 Sacramento Soil Moisture Accounting Model (SAC-SMA)与 Snow-17 的耦合模型媲美。顾逸^[10]在分析宜昌站年、月径流特性的基础上,提出了 Simple-LSTM 模型,较传统的前向型神经网络(Forward Neural Network, FNN)和支持向量机的预报精度更高、预报速度更快。冯钧等^[11]提出了一种多模型组合预报方法,将 LSTM、FNN 预报结果作为组合模型的输入进行二次训练,结果表明多模型组合提高了预报的稳定性和精确度。但与 LSTM 在生物、交通、电力等领域的应用相比^[12-16],目前 LSTM 在径流预测方面的应用广度和深度还存在明显差距,但具有较大发展潜力。本文尝试采用 LSTM 开展汉江上游安康站日径流预测工作。通过充分利用水文资料,挖掘出可利用的水文信息,分析不同输入条件下 LSTM 预测的精度,并与其他方法进行对比,可为流域水资源开发利用和洪水预测预警提供科学依据和定量工具。

1 研究方法

常用的 FNN 的隐层神经元对输入的处理是分离的,即前后 2 个输入之间没有任何联系,也就是不具有“记忆能力”,这是导致神经网络方法在处理时间序列信息模拟或预测时常难以取得满意效果的原因之一。为解决这一问题,人们发展了循环型神经网络(Recurrent Neural Network, RNN),RNN 在语音识别、机器翻译等方面得到了迅速应用,也被用于各类时间序列预报。但传统的 RNN 面临着递归权重矩阵维度爆炸和误差逆传播中梯度消失问题的困扰^[17],不能捕捉长期的时间关联性,故难以应用于以月、季甚至年为尺度的水文序列分析问题。

LSTM 是一种特殊的 RNN 网络,适合于处理和预测时间序列中间隔和延迟非常长的重要事件。相比于一般的 RNN, LSTM 的循环单元更为复杂,

每一个循环单元有一个额外的记忆状态 c_t 和若干控制信息流的门,包括输入门、记忆门、遗忘门和输出门。图 1 中 h_t 为隐含状态, x_t 为 t 时刻的输入, f_t, i_t, o_t, c_t 分别为 t 时刻的遗忘门、输入门、输出门和细胞状态。LSTM 的相关计算方法如下:

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \tag{1}$$

$$\tilde{c}_t = \tan h(W_c x_t + U_c h_{t-1} + b_c) \tag{2}$$

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \tag{3}$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \tag{4}$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \tag{5}$$

$$h_t = \tan h(c_t) \odot o_t \tag{6}$$

$$y = W_d h_t + b_d \tag{7}$$

式中: \tilde{c}_t 为记忆更新向量; $\sigma(\cdot)$ 表示 Sigmoid 函数, $\tan h(\cdot)$ 为双曲余弦函数; W 、 U 表示权重矩阵; b 表示偏置向量; \odot 表示向量标量积, y 为 t 时刻的输出。

LSTM 以不同滞时的序列作为输入,通过遗忘门、输入门和输出门调整循环单元的隐含状态向量与记忆状态向量,从而实现长短期记忆及序列预测。LSTM 的有效学习能力主要归功于循环单元中的记忆状态向量 c_t ,通过与前序单元的交互,可将前序输入信息有选择性地长期保留,而遗忘门控制前一时刻的记忆状态向量 c_{t-1} 中哪些元素会被遗忘。LSTM 中隐含状态向量和记忆状态向量的长度可以指定,且多个 LSTM 网络层可以叠置,只需按照输出的格式在最后时刻添加相应的密集层(也称全连接层)。

与其他神经网络模型一样,构建 LSTM 非常重要的一环是设计网络结构,即网络应包含的隐层数目和每一层的神经元数目,这些结构参数需要在学习之前确定,无法经训练过程得到,故也称为超参数(hyper-parameter)。对于传统的 FNN 模型,一般采用网格搜索方法确定超参数。但对于 LSTM 模型,

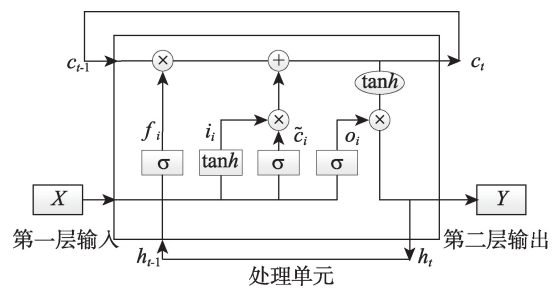


图1 LSTM 网络神经元结构示意图
Fig.1 Diagram of neuron structure of Long-Short Term Memory (LSTM)

其复杂度和输入样本的维度较高,不适宜采用网格搜索方法。可以根据经验设定一组超参数,然后通过试错法适当调整,根据模型精度确定网络结构。

2 研究对象与数据

2.1 研究对象

汉江是长江最大的支流,也是南水北调中线工程、引汉济渭等大型跨流域调水工程的水源地。本文以汉江上游的安康站(109°00'E、32°40'N)为研究对象。安康站控制流域处于中国南北过渡带,集水面积4.14万 km²,占汉江流域总面积的26%;流域内多年平均降水量为843.1 mm,平均径流量为187.0亿 m³。安康站以上还有汉中、石泉等水文站(图2,图中3个站点的集水区域均指站点以上的全部控制范围)。

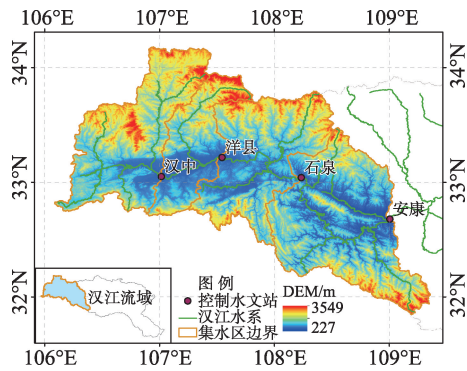


图2 研究区域与水文站点

Fig.2 The study area and hydrometric stations




图3 安康及其上游石泉站2013—2014年逐日径流过程(局部)

Fig.3 Daily runoff process of the Ankang Station and other three upper reach gauges, 2013—2014

2.2 数据资料

本文从汉江流域水文年鉴收集了安康、石泉2个水文站2003—2014年逐日径流资料。图3给出了2个站点2013—2014年逐日径流过程,表1给出了2003—2014年逐日径流资料有关统计指标。安康和石泉水文站的逐日径流序列具有相似的过程形态,年内年际变化均极其剧烈,主要区别在于洪峰流量量级不同。

同时收集了2003—2014年安康站控制流域逐日降水资料,来自于欧盟联合研究中心(EU/JRC)最新发布的多源加权集合降水数据(Multi-Source Weighted-Ensemble Precipitation, MSWEP),数据版本号2.1,时空分辨率分别为3 h和0.1°×0.1°。MSWEP是一种融合了地表雨量计、卫星降水和再分析降水资料的全球性降水数据集,其精度已在包括中国在内的世界各地得到了广泛检验。根据安康站集水范围,由MSWEP原始资料整理得到其集水范围内的逐日面平均雨量。

3 结果分析

安康站日径流与3类因素相关,即安康站自身前期径流量、安康站集水范围内前期面平均雨量序列和上游石泉站水文站前期径流量,可选择这3类因素中的一种或数种为预测输入变量预测安康站日径流量。根据可能的输入变量组合,共设置了7组预测方案,各方案的预见期(PT)为1~3 d,具体情况见表2。其中方案1~3分别仅采用一种预测输入变量,属第Ⅰ类方案;方案4~6有2种输入变量,属第Ⅱ类方案;方案7则将3类因素同时作为输入变量,属第Ⅲ类方案。对于每一种预测方案,根据预见期的不同,具体的输入变量又有所不同。以方案1为例,若预见期为1 d,则仅采用安康站前1日径流量作为输入;若预见期为2 d,则采用安康站前2日径流量作为输入,依此类推。

如第1节所述,LSTM模型的结构采用试错法确定,结合预测精度,对超参数进行反复调整,最终

表1 安康和石泉站2003—2014年逐日径流量统计指标

Tab.1 Daily runoff statistics of the Ankang and Shiquan stations, 2003—2014

站点	最大值 /(m ³ /s)	最小值 /(m ³ /s)	平均值 /(m ³ /s)	标准差 /(m ³ /s)	变差 系数
石泉	9770.0	3.6	315.2	628.9	2.0
安康	16800.0	0	588.7	965.8	1.6

确定 LSTM 的网络结构为双隐层, 每层神经元数目选为 20, 为防止过拟合, 在层间加入舍弃层(drop-out layer)。在确定网络结构时, 将 2003—2012 年作为训练期, 将 2013—2014 年作为检验期。精度指标采用均方根误差(Root-Mean-Square Error, RMSE)和纳什效率系数(Nash-Sutcliffe Efficiency coefficient, NSE), 两者计算公式如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Q_i^o - Q_i^s)^2} \quad (8)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (Q_i^o - Q_i^s)^2}{\sum_{i=1}^n (Q_i^o - \bar{Q}^s)^2} \quad (9)$$

式中: Q_i^o 和 Q_i^s 分别是径流预测值和观测值, \bar{Q}^s 为

表2 LSTM不同径流预测方案及输入变量

Tab.2 Different daily runoff predication schemes for Long-Short Term Memory (LSTM) and inputs setting

预测方案	模型输入变量			PT/d
	安康站前期径流序列	安康站集水范围前期雨量序列	安康站上游石泉站前期径流序列	
方案1	√			1~3
方案2		√		1~3
方案3			√	1~3
方案4	√	√		1~3
方案5	√		√	1~3
方案6		√	√	1~3
方案7	√	√	√	1~3

径流观测值的均值。RMSE 越小表明定量误差越小; NSE 越接近 1 表明径流预测值与观测值的过程吻合性越好。通常认为 NSE 大于一个设定的阈值时(0.5~0.65), 则模型的预测效果是可接受的^[18]。

表3给出了不同预测方案下安康站逐日径流预测精度指标。从中可知, 使用单一类型预测变量的方案 1~3 精度相对较低。以预见期为 1 d 的情况为例, 方案 1~3 在训练期 NSE 分别为 0.68、0.65 和 0.64。但这 3 种预测方案在检验期的精度较训练期均有所提升。方案 1 和方案 3 在检验期的 NSE 分别为 0.74、0.72(预见期 1 d), 而方案 2 在检验期的 NSE 也达到了 0.66; 同时, 各方案在检验期的 RMSE 较训练期有较大程度削减。

在采用 2 种预测变量后, 较仅采用 1 种预测变量的情况, 安康站日径流量预测精度有显著提高。对于预见期为 1 d 的情况, 方案 4~6 在训练期的 NSE 均在 0.72 以上, 最高达到了 0.79; 检验期 NSE 均在 0.76 及以上, 最高达到了 0.81; 与此同时, 方案 4~6 对应的 RMSE 较方案 1~3 也有明显降低。对于预见期为 2~3 d 的情况, 也有类似规律。对比方案 4~6 发现, 使用前期雨量和上游径流量组合为输入的方案 6 表现最优, 检验期 NSE 达到了 0.81, RMSE 仅为 347 m³/s。相对方案 1, 在检验期方案 6 的 NSE 提高了近 10%, RMSE 降低了近 14%。

同时采用安康站前期径流序列、前期降雨序列和上游站前期径流序列 3 种输入的方案 7 的表现是

表3 不同 LSTM 预测方案对应的安康站日径流预测精度指标

Tab.3 Accuracy of daily runoff prediction of the Ankang Station by different schemes based on Long-Short Term Memory (LSTM) model

预测方案	精度指标	PT=1 d		PT=2 d		PT=3 d	
		训练期	检验期	训练期	检验期	训练期	检验期
方案1	NSE	0.68	0.74	0.43	0.58	0.34	0.47
	RMSE/(m ³ /s)	529	403	711	511	763	573
方案2	NSE	0.65	0.66	0.54	0.54	0.39	0.43
	RMSE/(m ³ /s)	554	456	638	534	734	594
方案3	NSE	0.64	0.72	0.46	0.60	0.36	0.54
	RMSE/(m ³ /s)	566	419	694	499	755	532
方案4	NSE	0.77	0.77	0.58	0.62	0.43	0.49
	RMSE/(m ³ /s)	456	373	610	487	713	559
方案5	NSE	0.72	0.76	0.49	0.62	0.39	0.54
	RMSE/(m ³ /s)	496	381	669	484	735	532
方案6	NSE	0.79	0.81	0.61	0.65	0.43	0.51
	RMSE/(m ³ /s)	430	347	590	463	712	548
方案7	NSE	0.83	0.84	0.62	0.67	0.43	0.56
	RMSE/(m ³ /s)	384	316	581	454	708	525

所有方案中最优的,其精度较方案6有进一步的提高。当预见期为1 d时,其在训练期和检验期的NSE分别达到了0.83和0.84,明显高于其他方案;RMSE仅为384 m³/s和316 m³/s,明显低于其他方案。相比方案1,在检验期方案7的NSE提升了近14%,RMSE降低了近22%。

当预见期从1 d延长至2、3 d时,各方案的预测精度均不断降低。对于第 I 类方案,方案1在训练期和检验期的NSE均不足0.6,方案2也不超过0.6;第 II 类方案中精度最高的方案6,其在训练期和检

验期的NSE分别为0.61和0.65(PT=2 d);方案7的精度在3类方案中仍然最高,预见期为2 d时训练期和检验期的NSE分别为0.62和0.67。当PT=3 d时,7个方案的预测精度均不甚理想。

图4~图6分别给出了预见期为1 d时,方案1、方案4和方案7对安康站逐日径流预测的结果(2013—2014年)。根据图4,方案1对应的日径流预测过程与实测序列总体上是较为接近的,两者过程较为接近,但对主要洪峰有一定程度的低估。方案4同时利用安康站前期径流和雨量进行预测,径流




图4 LSTM模型安康站检验期逐日径流预测结果(方案1)

Fig.4 Daily runoff prediction results of Long-Short Term Memory (LSTM) by Scheme 1 at the Ankang Station




图5 LSTM模型安康站检验期逐日径流预测结果(方案4)

Fig.5 Daily runoff prediction results of Long-Short Term Memory (LSTM) by Scheme 4 at the Ankang Station




图6 LSTM模型安康站逐日径流预测结果(方案7)

Fig.6 Daily runoff prediction results of Long-Short Term Memory (LSTM) by Scheme 7 at the Ankang Station

过程预测值和观测值的吻合性在汛期和非汛期表现出不同的特征,非汛期两者的吻合度较高,而汛期预测结果对小洪峰有一定高估(对主洪峰同样存在低估);方案7在主要洪峰流量的估计上较方案1和方案4有明显改善。

总的来看,LSTM模型在检验期的表现不低于甚至要优于训练期,说明LSTM训练时对过拟合的控制较好,未出现明显泛化误差。从单变量方案、双变量方案到三变量方案,LSTM模型的径流预测精度大致呈阶段性上升,这说明LSTM网络具有较强学习能力,能够充分挖掘安康站日径流序列与相关的各种前期影响因素的可利用性,在1 d有效预见期的基础上实现较准确的径流预测。而当PT=2~3 d时,模型的预测精度显著降低,则说明在日时间尺度上安康站径流过程具有很强的动态变化特征,当相距时间延长时前期相关信息对当前日径流量的影响程度在快速降低。

4 结论与讨论

作为一种特殊的循环型神经网络,LSTM能够捕捉水文序列的长期时间关联性。本文基于LSTM,以2003—2014年安康站自身前期径流量、安康站集水范围内前期面平均雨量序列和上游石泉站前期径流量及其组合作为输入变量,建立了汉江上游安康站日径流预测模型,对不同预测方案的效果进行了分析比较,主要结论如下:

(1) LSTM模型能够捕捉安康站日径流序列的长期时间关联性,随着有效输入变量增多,其预测效果更好。以安康站自身前期径流量、安康站集水范围内前期面平均雨量序列和上游石泉站前期径流量的预测方案在所有方案中的精度最高,预见期为1 d的情况下,训练期和检验期的NSE分别达到了0.83和0.84。

(2) LSTM在一定程度上避免了日径流预测过程中过拟合的问题。安康站各预测模型在检验期的表现不低于甚至要优于训练期,说明LSTM训练时对过拟合的控制较好,未导致明显的泛化误差。

(3) 在1 d有效预见期的基础上实现较准确的径流预测,当预见期从1 d延长至2、3 d时,各方案的预测精度显著降低。说明在日时间尺度上安康站径流过程具有很强的动态变化特征,当相距时间延长时前期相关信息对当前日径流量的影响程度

在快速降低。

需指出的是,本文仅开展LSTM模型在径流预测中的初步研究。相比于传统的FNN以及其他数据驱动模型,LSTM在理论上具有独特优势,但其预测效果和能力还需要通过在各种情况下验证以及与其他模型的全面比较加以充分说明。

参考文献(References)

- [1] Liang X, Liang Y. Applications of data mining in hydrology [C]// Proceedings 2001 IEEE International Conference on Data Mining. San Jose, USA, 2001: 617-620.
- [2] Kurtulus B, Razack M. Modeling daily discharge responses of a large karstic aquifer using soft computing methods: Artificial neural network and neuro-fuzzy [J]. Journal of Hydrology, 2010, 381(1): 101-111.
- [3] Tiwari M K, Chatterjee C. A new wavelet-bootstrap-ANN hybrid model for daily discharge forecasting [J]. Journal of Hydroinformatics, 2011, 13(3): 500-519.
- [4] 赵铜铁钢, 杨大文. 神经网络径流预报模型中基于互信息的预报因子选择方法 [J]. 水力发电学报, 2011, 30(1): 24-30. [Zhao Tongtiegang, Yang Dawen. Mutual information-based input variable selection method for runoff-forecasting neural network model. Journal of Hydroelectric Engineering, 2011, 30(1): 24-30.]
- [5] 刘柯. 基于主成分分析的BP神经网络在城市建成区面积预测中的应用: 以北京市为例 [J]. 地理科学进展, 2007, 26(6): 131-139. [Liu Ke. Application of BP Neural Network based on principal component analysis in urban area prediction: A case study of Beijing. Progress in Geography, 2007, 26(6): 131-139.]
- [6] 李爱云, 张红霞. 小波人工神经网络在径流预报中的应用 [J]. 人民黄河, 2011(10): 37-38, 41. [Li Aiyun, Zhang Hongxia. Wavelet neural network model and its application in runoff forecasting. Yellow River, 2011(10): 37-38, 41.]
- [7] 郭昊, 张艳军, 王俊勃, 等. 长短期记忆模型在小流域洪水预报上的应用研究 [J]. 水资源研究, 2019(1): 24-32. [Guo Jiong, Zhang Yanjun, Wang Junbo, et al. Application of the long short-term memory networks for flood forecast. Journal of Water Resources Research, 2019(1): 24-32.]
- [8] 周研来, 郭生练, 张斐章, 等. 人工智能在水文预报中的应用研究 [J]. 水资源研究, 2019(1): 1-12. [Zhou Yanlai, Guo Shenglian, Zhang Feizhang, et al. Hydrological forecasting using artificial intelligence techniques. Journal of Water Resources Research, 2019(1): 1-12.]
- [9] Kratzert F, Klotz D, Brenner C, et al. Rainfall-runoff modelling using long short-term memory (LSTM) networks

- [J]. *Hydrology and Earth System Sciences*, 2018, 22(11): 6005-6022.
- [10] 顾逸. 基于长短期记忆循环神经网络及其结构约减变体的中长期径流预报研究 [D]. 武汉: 华中科技大学, 2018. [Gu Yi. Medium and long-term runoff prediction based on long-term and short-term memory-cycle neural networks and their structural reductions. Wuhan, China: Huazhong University of Science and Technology, 2018.]
- [11] 冯钧, 潘飞. 一种 LSTM-BP 多模型组合水文预报方法 [J]. *计算机与现代化*, 2018(7): 82-85. [Feng Jun, Pan Fei. A hydrologic forecast method based on LSTM-BP. *Computer and Modernization*, 2018(7): 82-85.]
- [12] 刘桐彤. 基于长短期记忆神经网络的短期负荷预测方法 [J]. *黑龙江科技信息*, 2016(31): 81. [Liu Tongtong. Short-term load forecasting method based on long-term and short-term memory neural network. *Heilongjiang Science and Technology Information*, 2016(31): 81.]
- [13] 刘炳春, 齐鑫, 王庆山. 北京城市代谢预测研究: 基于长短期记忆神经网络模型 [J]. *地理科学进展*, 2019, 38(6): 851-860. [Liu Bingchun, Qi Xin, Wang Qingshan. Urban metabolism prediction of Beijing City based on long short-term memory neural network. *Progress in Geography*, 2019, 38(6): 851-860.]
- [14] 晏臻, 于重重, 韩璐, 等. 基于 CNN+LSTM 的短时交通流量预测方法 [J]. *计算机工程与设计*, 2019, 40(9): 2620-2624, 2659. [Yan Zhen, Yu Chongchong, Han Lu, et al. Short-term traffic flow prediction method based on CNN+LSTM. *Computer Engineering and Design*, 2019, 40(9): 2620-2624, 2659.]
- [15] 陶晔, 杜景林. 基于随机森林的长短期记忆网络气温预测 [J]. *计算机工程与设计*, 2019, 40(3): 144-150. [Tao Ye, Du Jinglin. Temperature prediction using long short term memory network based on random. *Computer Engineering and Design*, 2019, 40(3): 144-150.]
- [16] Guo J M, Markoni H. Driver drowsiness detection using hybrid convolutional neural network and long short-term memory [J]. *Multimedia Tools and Applications*, 2019, 78(20): 29059-29087.
- [17] Hochreiter S, Schmidhuber J. Long short-term memory [J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [18] Ritter A, Muñoz-Carpena R. Performance evaluation of hydrological models: Statistical significance for reducing subjectivity in goodness-of-fit assessments [J]. *Journal of Hydrology*, 2013, 480: 33-45.

Daily runoff predication using LSTM at the Ankang Station, Hanjing River

HU Qingfang¹, CAO Shiyi¹, YANG Huibin^{1,2}, WANG Yintang¹, LI Linjie¹, WANG Lihui²

(1. State Key Laboratory of Hydrology-Water Resources and Hydraulic Engineering,
Nanjing Hydraulic Research Institute, Nanjing 210029, China;

2. Department of Water Resources, Hydropower and PortEngineering, Fuzhou University, Fuzhou 350116, China)

Abstract: Based on the hydrological data from 2003 to 2014, Long-Short Term Memory (LSTM) was used to construct a daily runoff prediction model for the Ankang discharge station in the upper reaches of the Hanjiang River. The accuracy of daily runoff prediction was evaluated under different input conditions. The result shows that when the foreseeing period is one day, the efficiency coefficient of the LSTM in the calibration period and the validation period can reach 0.68 and 0.74 respectively under the condition that only the previous daily runoff of the Ankang Station is used as input. When the previous areal rainfall of the catchment and the previous daily runoff of the upstream Shiquan Station were added to the LSTM model as input variables, the daily runoff prediction precision was improved. The efficiency coefficient of the training period and the validation period could reach 0.83 and 0.84, respectively. The root mean square error was also significantly reduced. The accuracy of the main flood peak flow forecasting also increased. The LSTM can effectively avoid the problem of over-fitting, and has better generalization performance. However, when the foreseeable period is extended from one day to two or three days, the performance of LSTM is significantly reduced.

Keywords: long-short term memory; daily runoff forecast; Hanjiang River Basin; Ankang Station