

DOI: 10.19797/j.cnki.1000-0852.20210457

# 深度学习的LSTM-GRU复合模型在水文模拟中的应用

陆冠宇<sup>1,2</sup>, 刘文强<sup>1,2</sup>, 郝慧清<sup>1,2</sup>, 王奇<sup>3</sup>, 郝永红<sup>2</sup>

(1.天津师范大学 地理与环境科学学院,天津 300387;

2.天津师范大学 天津市水资源与水环境重点实验室,天津 300387;

3.天津师范大学 数学科学学院,天津 300387)

**摘要:**在深度学习中,长短期记忆网络(LSTM)和门控循环单元(GRU)是两种模拟时间序列、循环神经网络(RNN)的主要基础结构,各有优缺点。为弥补二者的不足,提高河流流量的预测精度,建立了LSTM-GRU复合模型,并用于海河流域大清河水系白沟河流域流量的预测。基于东茨村水文站2006—2019年的日观测数据,以8个水文气象因子(气压、水温、相对湿度、降水量、日照、地温、风速、水位)的观测数据为输入,河流流量为输出,建立LSTM-GRU水文模型。为验证该模型的优势,将LSTM-GRU的模拟结果分别与LSTM和GRU的结果进行比较。结果表明,LSTM-GRU复合模型的稳定性和精确度明显优于单一的LSTM或GRU模型,为河流流量预测提供了一个更精准的方法。

**关键词:**深度学习;长短期记忆网络(LSTM);门控循环单元(GRU);移动平均;流量预测

**中图分类号:**TV11;P33

**文献标识码:**A

**文章编号:**1000-0852(2023)03-0052-08

## 0 引言

我国是世界上洪涝灾害发生最为频繁的国家之一,精准掌握水文变化的基本规律对于流域防洪抗旱、风险评估有着重要作用。河流流量预测是水文变化研究的一项重要内容,对于水资源管理、洪涝等自然灾害预警等方面具有重要的指导意义和参考价值<sup>[1]</sup>。

传统的流量预测方法主要分为两种:物理模型预测和数理统计预测。物理模型预测法需要相应的实验条件和大量基础数据,且模型制作需要投入大量人力、财力和时间,对于处理复杂的水文数据不易实现。数据统计预测方法适用于预测线性和均匀模式的序列数据,但难以处理像流量这种复杂的、非均匀的、非线性的数据<sup>[2-3]</sup>。

近年来,神经网络(ANN)发展迅速,且具有很强的非线性拟合能力以及易于构建、自适应等特

点,可以用于不同的水文环境<sup>[4]</sup>,已被应用到水文研究领域。循环神经网络(RNN)是一种特殊类型的ANN,适合处理时间序列数据;但由于它的多层正向结构,在调参寻优过程中容易出现梯度衰减或梯度爆炸问题<sup>[5]</sup>。为了解决以上问题,长短期记忆网络(LSTM)和门控循环单元(GRU)应运而生<sup>[6-7]</sup>。但在数据量较大情况下,LSTM参数多,运行时间长,且在模拟具有强烈非线性和波动的多频率时间序列方面存在明显不足<sup>[8]</sup>;而GRU参数少,收敛速度快,可以大大缩短预测时间,但GRU对波动较大的水文数据更加敏感,稳定性较差<sup>[9]</sup>。为了解决单一模型存在缺陷问题,Bates和Granger<sup>[10]</sup>提出“组合预测”概念。组合模型综合各个预测模型的优点,弥补单个模型在预测过程中的不足,进而提高预测精度<sup>[11]</sup>。本文基于LSTM和GRU建立LSTM-GRU复合模型进行流量预测,并将LSTM-GRU模拟结果与LSTM和GRU模拟结果进行对比分析,进而探讨复合模型的精准度和适用性。

收稿日期:2021-11-06

网络首发日期:2023-04-06

网络首发地址:<https://kns.cnki.net/kcms/detail/11.1814.P.20230404.1706.008.html>

基金项目:国家自然科学基金资助项目(42072277, 41272245, 40972165)

作者简介:陆冠宇(1997—),男,山西大同人,研究生,主要研究方向为水文地理。E-mail: 1628157731@qq.com

通信作者:郝永红(1964—),男,山西平遥人,教授,主要研究方向为水文地理。E-mail: haoyh@sxu.edu.cn

### 1 研究方法

#### 1.1 长短期记忆网络(LSTM)

LSTM 最初是由 Hochreiter 和 Schmidhuber<sup>[6]</sup> 在 1997 年提出来的。LSTM 基本结构由输入层、1 个或多个隐含层以及输出层组成。LSTM 单元结构见图 1。

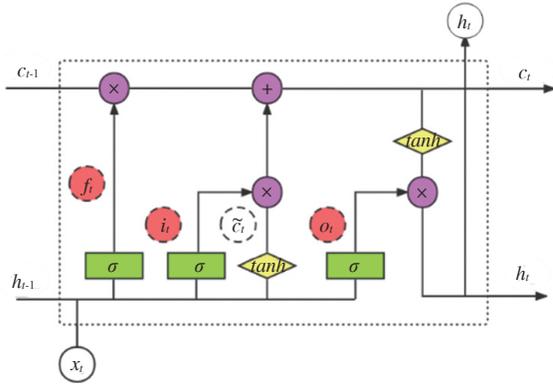


图1 LSTM单元结构  
Fig.1 LSTM unit structure diagram

LSTM 主要由遗忘门( $f_t$ )、输入门( $i_t$ )、输出门( $O_t$ )和状态元组成记忆单元来控制信息取舍,从而实现遗忘或记忆的功能,较好地解决了 RNN 的长期依赖问题,避免梯度消失或爆炸的问题。图 1 中, $\times$ 以及 $+$ 为节点; $\sigma$ 为 sigmoid 函数; $h_t$ 为  $t$ 时刻隐含层输出向量; $x_t$ 和  $h_{t-1}$ 分别为  $t$ 、 $t-1$ 时刻输入向量; $\tilde{c}_t$ 为  $t$ 时刻通过  $i_t$ 的候选信息状态, $C_t$ 为  $t$ 时刻的状态单元; $\tanh$ 为双曲正切激活函数<sup>[12]</sup>。

#### 1.2 门控循环单元(GRU)

2014 年,Cho 等<sup>[7]</sup>提出了门控循环单元(GRU)。GRU 作为 LSTM 的一种变体,将遗忘门和输入门合成了一个单一的更新门。GRU 中没有传送带似的状态单元,但保留了隐藏状态。最终的 GRU 比标准的 LSTM 模型简单,单元结构见图 2。

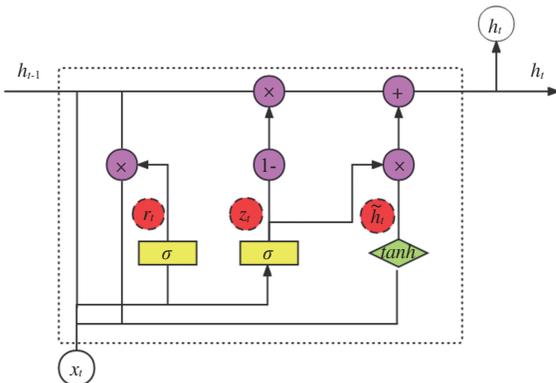


图2 GRU单元结构  
Fig. 2 GRU unit structure diagram

图 2 中  $r_t$  和  $Z_t$  分别为重置门和更新门。在 GRU 中,不具有 LSTM 中专门储存记忆的单元  $C_t$ ,而是将所有信息放进隐藏状态  $h_t$  中。利用更新门  $Z_t$  在上一个隐藏状态  $h_{t-1}$  和重置后中途隐藏状态  $h_t$  做一个权衡,这里的  $Z_t$  经过激活函数  $\sigma$  的作用后变成 0 和 1 之间的数。 $Z_t$  越接近 1,代表在  $t$  时刻“记忆”下来的数据越多;而越接近 0 则代表“遗忘”的越多<sup>[13]</sup>。图 2 中: $\sigma$  为 sigmoid 函数; $x_t$  为  $t$  时刻的输入向量; $h_t$ 、 $h_{t-1}$  为  $t$  时刻和  $t-1$  时刻的隐藏状态。

#### 1.3 LSTM-GRU 复合模型

本文提出将 LSTM-GRU 复合模型应用于流量预测。LSTM-GRU 复合模型的结构见图 3。

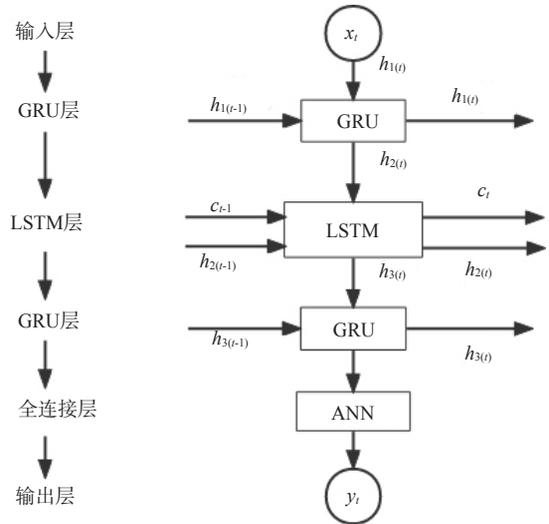


图3 LSTM-GRU 复合模型结构  
Fig.3 LSTM-GRU combined model structure diagram

GRU 作为模型结构的第一层,有助于加快训练速度和避免模型过拟合;再经过 LSTM 层,很好地避免了模型长期依赖的问题,防止梯度弥散;接着又经过一层 GRU 层,加快模型收敛速度,缩短预测结果时间;最后输入到全连接层,主要目的是将向量转为实数,最后输出数据。这样复合不仅有效避免了过拟合与梯度消失问题,而且加快了训练速度,节约计算成本。

#### 1.4 移动平均法

移动平均法是一种简单的平滑数据处理技术,即在简单平均数法基础上,通过对时间序列数据逐项推移增减数值,借以消除数据的随机起伏,使其变化平滑,以反映时间序列数据长期变化趋势的方法<sup>[14]</sup>。降水是一种稀疏序列数据<sup>[15]</sup>。由于气候原因,数据中含有大量为 0 的数据且异常值多、不稳定性强,数据特征不能反映河流汇流过程。因此本文运用此方法处理非平稳降雨数据。移动平均的计算,见式(1)。

$$b_t = (d_{t-1} + d_{t-2} + \dots + d_{t-n})/n, t > n \quad (1)$$

式中:  $b_t$  为对下一期的预测值;  $d_{t-1}, d_{t-2}, d_{t-n}$  分别表示前1期、前2期直至前  $n$  期的实际值;  $n$  为周期数(即每次求移动平均所使用实际值个数)。

### 1.5 模型的评价

本文以纳什效率系数(NSE)和均方根误差(RMSE)为评价指标<sup>[16]</sup>,对预测结果进行评价,反映模型的拟合精度。

## 2 研究区概况及数据

### 2.1 研究区自然地理特征

本文选取海河流域大清河水系为研究对象,白沟河东茨村水文站位于河北省涿州市东茨村。白沟河属海河流域大清河水系,大清河是海河水系五大河之一,位于  $113^{\circ}40' \sim 117^{\circ}E$ 、 $38^{\circ}10' \sim 40^{\circ}N$  之间。大清河全长 483 km,流域面积 43 296 km<sup>2</sup>。大清水系处于温带季风区,受海洋及地形影响,降雨量年际变化大、分配不均,故经常出现连年干旱或旱涝交替等情况<sup>[17]</sup>。因此,选取此区域作为研究对象,对海河流域水资源管理以及洪涝等自然灾害预警等方面具有重要的参考价值。大清河流域水系及水文站分布信息见图4。

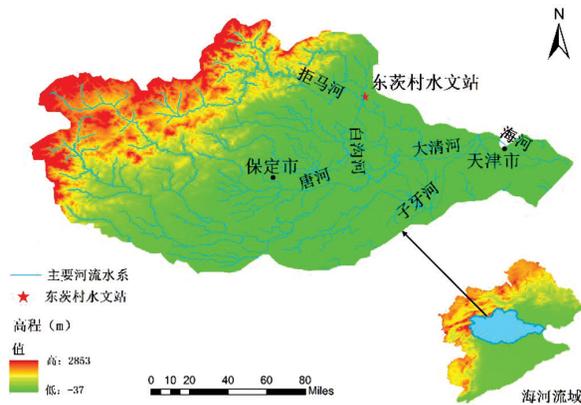


图4 大清河流域水系及水文站分布信息  
Fig.4 Distribution information of water system and hydrological stations in Daqing River Basin

### 2.2 数据来源与选取

本文所用水文日数据来源于水文年鉴《海河流域水文资料》,选取白沟河流域东茨村水文站2006年1月1日至2019年12月31日数据作为研究对象,包括流量、降水量、水位和水温。选用来源于中国科学院地理科学与资源研究所资源环境科学与数据中心(<https://www.resdc.cn/>)相同时间段的气象

日数据作为研究对象,包括地温、气压、相对湿度、日照时数和风速。

不同于传统的思维模式,我们首先分析水文气象因素对河道流量的影响与贡献,确定其中的关键影响因素;深度学习直接利用数据驱动学习建模、挖掘隐藏在数据背后的规律。最大的优点是通过大量输入数据的训练获取数据集的有效特征,省略了人工设计特征提取的环节。一般来说,数据量越大,模型表现越好<sup>[18]</sup>。基于以上原理并根据当地自然地理条件,我们选择了8个水文气象因素作为输入变量。以气压、水温、相对湿度、降水量、日照、地温、风速、水位作为输入变量或自变量,流量作为输出变量或因变量(见图5)。

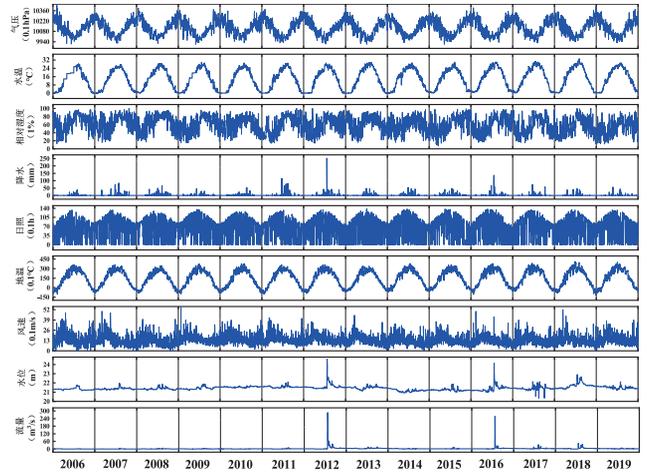


图5 大清河流域每日水文和气象数据  
Fig.5 Daily hydrological and meteorological data of the Daqing River basin

从图5看出,气压、水温、相对湿度、地温和日照时数每年都出现较大波动。降水主要集中在7-8月的雨季,河流流量和水位的峰值也出现在雨季。

## 3 结果与讨论

### 3.1 训练期与验证期的划分

将收集到的2006—2019年水文气象日数据划分为训练期(2006—2015年)和验证期(2016—2019年)两个集合。以气压、水温、相对湿度、移动平均后的降水量、日照、地温、风速、水位等8个变量为输入,河流流量为输出。建立包括LSTM,GRU和LSTM-GRU的深度神经网络模型,并利用这些模型对河流流量进行预测。

### 3.2 模型的参数识别

在深度学习的模型中隐含层的层数,每层隐藏神

神经元个数对模拟效果有很大影响。层数或者每层神经元个数过多,都会造成过拟合现象;相反,层数或者每层神经元个数过少,则表明网络映射能力不足,可能出现欠拟合现象<sup>[9]</sup>。对于隐含层内神经元数量以及其他参数,本文采用“试错法”,通过比较不同参数输出结果与真实值的拟合效果,来确定合适的参数。

在 LSTM 模型中,设置 3 层隐含层,其神经元个数分别为 45、35 和 25;最后 1 层全连接层作为输出层,神经元个数为 1。批量大小设置为 64,训练轮数为 610,学习率为 0.008,优化器选择 Adam,选取均方误差 (MSE) 作为损失函数,时序步长设置为 6,隐含层激活函数选用 sigmoid 函数,结果见表 1。

在 GRU 模型中,GRU 神经网络共设置 1 层输入层、3 层隐含层和 1 层输出层结构。隐含层由 3 层 GRU 层构成。为了便于比较,除了学习率为 0.005、训练轮数为 580,比 LSTM 模型超参数小,其余超参数设置与 LSTM 都一样,结果见表 1。

LSTM-GRU 复合模型中,其神经网络除了隐含层第一层为 GRU 层,第二层为 LSTM 层,第三层为 GRU 层,其余超参数设置与 GRU 模型都一样,结果见表 1。

表 1 模型最终参数设置

Table1 Model final parameter setting

参数名称	各模型参数值		
	LSTM	GRU	LSTM-GRU
批量大小	64	64	64
训练轮数	610	580	580
学习率	0.008	0.005	0.005
隐含层激活函数	sigmoid	sigmoid	sigmoid
时序步长	6	6	6
优化器	Adam	Adam	Adam
损失函数	MSE	MSE	MSE
隐含层层数及各层名称	3 层 LSTM	3 层 GRU	第一层 GRU, 第二层 LSTM, 第三层 GRU
隐含层神经元个数	45、35、25	45、35、25	45、35、25
全连接层层数	1	1	1

根据我们收集到的水文气象数据对 LSTM、GRU 和 LSTM-GRU 的参数进行了训练。为了检验模型在训练和验证期是否过拟合,本文根据三个模型迭代过程中损失值的变化做了验证图。LSTM、GRU 和 LSTM-GRU 在训练期和验证期的损失值变化曲线见图 6。

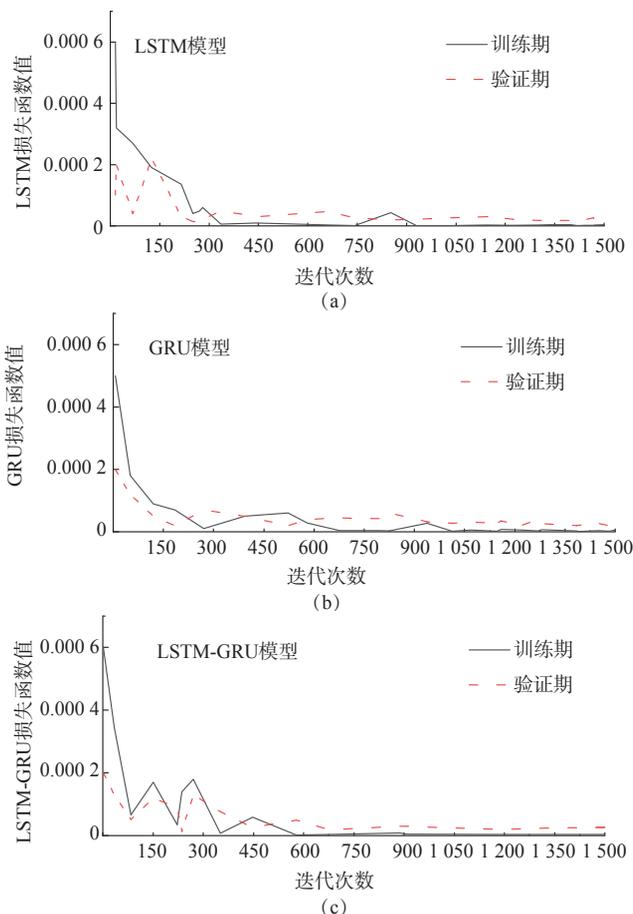


图 6 模型训练和验证期的损失值变化曲线

Fig.6 The loss value variation curves of the training and verification period

由图 6 可知,三个模型在训练和验证期的损失值下降并最终趋于稳定,未出现过拟合或欠拟合现象,表明训练效果良好。同时可以看出,当训练次数达到 600 以上时,LSTM-GRU 训练期与验证期损失函数值变化曲线相对于 LSTM 与 GRU 变化曲线更稳定。

时序步长是在循环神经网络中每个单位迭代的次数,同时也代表了输出数据与之前依次输入数据依赖关系,表征时间序列的自相关性。时序步长不同,模型预测效果也有很大不同。三个模型在不同时序步长下验证期纳什效率系数(NSE)变化见图 7。

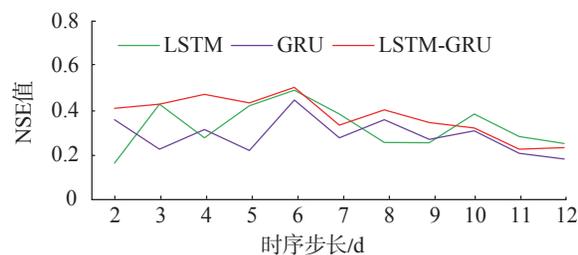


图 7 模型在不同时序步长下验证期 NSE 值变化曲线

Fig.7 NSE in validation period under different time series steps

由图7可知,三个模型在时序步长为6天时NSE值达到最高,LSTM-GRU的NSE值略高于LSTM和GRU。三个模型NSE值随着时序步长增加呈整体下降趋势。

### 3.3 模型验证及结果分析

在降水形成径流过程中,由于植物土壤等的存在,通过不同路径的降水在形成径流过程中具有时滞或者拖尾效应。为此,本文对原始降水数据进行了间隔时长为2~18天的移动平均。对率定好的数据集,利用机器学习方法建立LSTM、GRU和LSTM-GRU模型,并以2016—2019年数据进行验证。根据纳什效率系数(NSE)和均方根误差(RMSE),分别计算三种模型训练期与验证期在间隔2~18天的统计指标。结果见表2。

由表2可知,在移动平均时长为12天时,三个模型的平均NSE值达到最高(训练期为0.998,验证期0.77),高于其它移动平均时长的平均NSE值。同时,平均RMSE值也达到最小(训练期为0.34,验证期为4.00),小于其它移动平均时长的平均RMSE值。相比来说,LSTM-GRU表现出更高的预测精度。此外,我们发现LSTM预测精度有时优于GRU,但有时GRU预测精度优于LSTM,而LSTM-GRU总体上预测精度优于LSTM与GRU。我们可以从模型结构上分析其中原因:LSTM有三个门,比拥有两个门的GRU结构更复杂,参数更多。因此,在相同数

据量情况下,GRU需要较少的计算就可以达到与LSTM一样的效果,这表明GRU的收敛速度更快。二者主要区别在于:GRU直接将隐藏状态传给下一个单元,不作任何控制;而LSTM则用输出门控制传输到下一个单元。LSTM在计算新的向量时,对上一时刻的信息不做任何控制,而是用遗忘门独立的实现这一功能。GRU在计算新的向量时,利用重置门来对上一时刻的信息进行控制。LSTM可以记住更多的内容,因为它有专门储存记忆的状态元,所以LSTM比GRU可以捕获更多的信息;但由于LSTM参数多,所以它比GRU对过拟合更敏感。由于结构不同,GRU对数据更敏感,而LSTM更具体。LSTM-GRU很好的综合了LSTM与GRU的优点,弥补了各自的不足。因此,无论从稳定性还是精度上,都比单一结构的模型性能要好。

为了验证上述结果,选取三个模型移动平均时长预测精度最高12天数据的结果,分为训练期(2006—2015年)和验证期(2016—2019年)进行试验。三个模型训练期与验证期的实测流量与模拟流量预测结果的对比折线图见图8,实测流量与模拟流量预测结果的散点图见图9。

由图8可知,在训练期,三个模型整体预测效果均表现良好,但LSTM-GRU对流量峰值的预测效果优于LSTM和GRU。在验证期,对于流量峰值,三个模型的

表2 模型训练期与验证期精度

Table2 The precision of model training and validation period

移动平均 间隔时长 /d	训练期精度						验证期精度					
	NSE			RMSE			NSE			RMSE		
	LSTM	GRU	LSTM-GRU	LSTM	GRU	LSTM-GRU	LSTM	GRU	LSTM-GRU	LSTM	GRU	LSTM-GRU
2	0.997	0.994	0.997	0.40	0.58	0.40	0.77	0.62	0.59	4.12	5.23	5.43
3	0.98	0.98	0.995	1.28	1.05	0.51	0.66	0.59	0.72	4.96	5.46	4.48
4	0.996	0.997	0.998	0.50	0.44	0.31	0.80	0.57	0.60	3.79	5.61	5.37
5	0.996	0.993	0.997	0.47	0.63	0.44	0.72	0.67	0.60	4.52	4.88	5.37
6	0.996	0.995	0.997	0.50	0.54	0.40	0.69	0.78	0.72	4.78	3.96	4.49
7	0.996	0.996	0.998	0.45	0.48	0.32	0.78	0.72	0.71	4.03	4.54	4.61
8	0.997	0.997	0.997	0.44	0.40	0.42	0.78	0.75	0.72	4.01	4.23	4.49
9	0.994	0.994	0.995	0.55	0.58	0.55	0.69	0.80	0.80	4.76	3.80	3.78
10	0.95	0.994	0.995	1.42	0.54	0.53	0.69	0.62	0.76	4.75	5.27	4.17
11	0.998	0.97	0.997	0.31	1.29	0.39	0.72	0.71	0.77	4.52	4.60	4.10
12	0.997	0.996	0.998	0.38	0.48	0.32	0.79	0.71	0.80	3.90	4.59	3.52
13	0.996	0.996	0.994	0.47	0.46	0.57	0.71	0.62	0.72	4.58	5.25	4.52
14	0.998	0.995	0.998	0.37	0.54	0.32	0.55	0.68	0.71	5.75	4.87	4.57
15	0.972	0.997	0.996	1.24	0.50	0.46	0.63	0.66	0.76	5.23	3.79	4.15
16	0.994	0.994	0.997	0.56	0.56	0.45	0.72	0.68	0.74	4.56	4.82	4.36
17	0.995	0.997	0.997	0.52	0.41	0.39	0.67	0.72	0.75	4.92	4.55	3.91
18	0.989	0.993	0.997	0.78	0.63	0.41	0.65	0.70	0.76	5.05	4.66	4.17

预测值总是小于实测值, LSTM-GRU 预测结果更接近流量峰值; 在流量值低时, LSTM、GRU 出现异常波动值, LSTM-GRU 预测更稳定, 模拟效果表现更好。因此, LSTM-GRU 具有更好的非线性仿真能力。

从图 9 可知, LSTM-GRU 在训练期与验证期的  $R^2$  分别为 0.9984 和 0.8527, 相对于 LSTM 和 GRU 表现更好。在验证期中, LSTM 和 GRU 中的数据显得较为松散, 而 LSTM-GRU 中的数据相对更接近拟合直线。结果表明, LSTM-GRU 比 LSTM 和 GRU 具有更好的流量预测效果, 能更好地反映实测流量与模拟流量之间的关系。

为了进一步确认 LSTM-GRU 复合模型的模拟效果, 选取三个模型针对 2016—2019 逐年的河流最大流量和最小流量的预测值与实测值进行对比。结果见表 3。

由表 3 可知, LSTM-GRU 复合模型对流量高低值的预测结果与实测值误差最小, 进一步确认了 LSTM-GRU 复合模型在河流流量高低值预测中精度高于单一的 LSTM 或 GRU 模型。另外, 由于最大流量和最小流量是小样本数据, 深度学习模型不能充分学习和掌握这类数据所反映的规律, 因此, 三个模型对最大最小流量的预测存在一定误差。

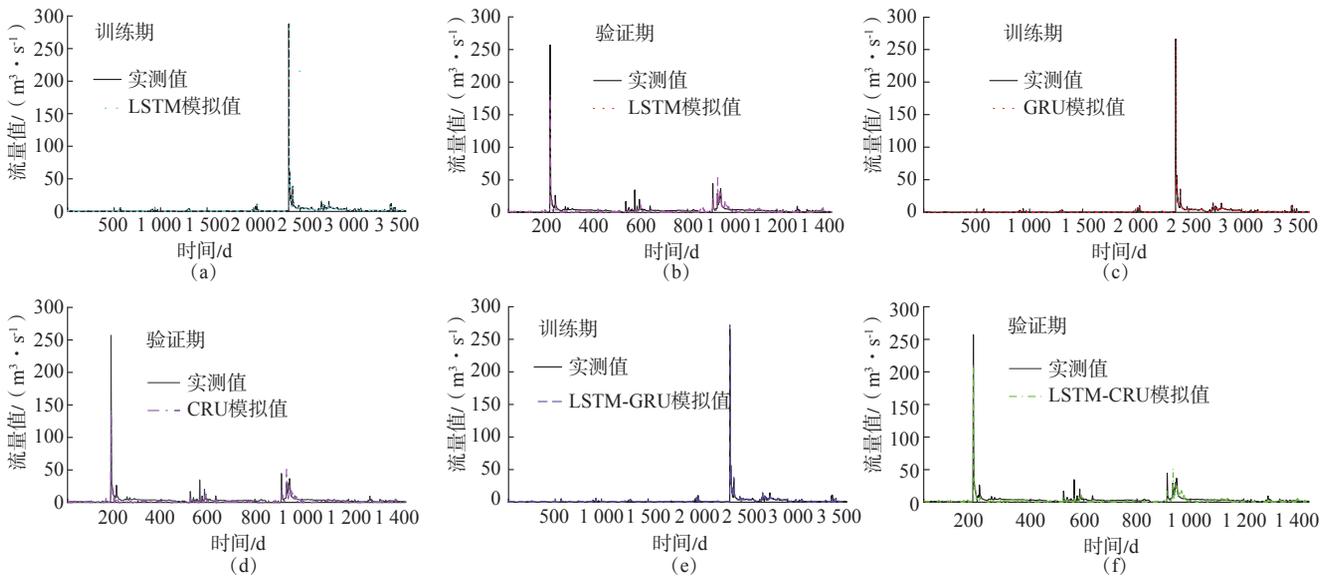


图 8 模型实测流量和模拟流量预测结果的过程线对比

Fig.8 Comparison of process line between the predicted results of measured flow rate and simulated flow rate

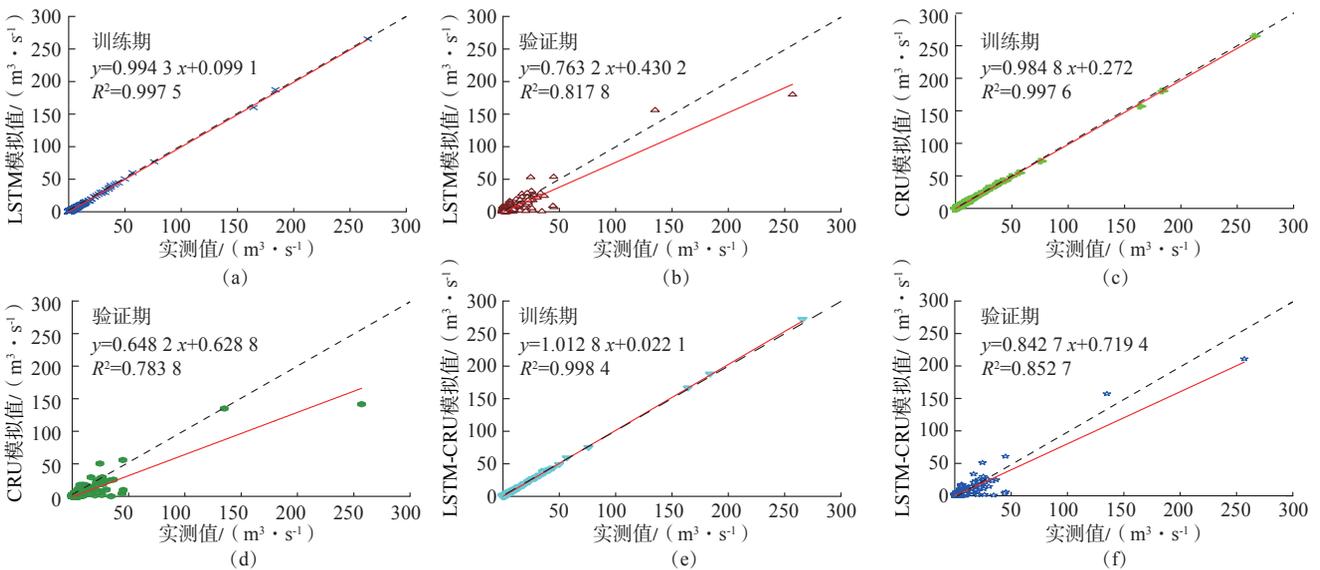


图 9 模型实测流量和模拟流量预测结果的散点图

Fig.9 Scatter diagram of the predicted results of measured and simulated flow

表3 模型2016—2019年的河流最大最小流量预测值与实测值的对比

Table3 Comparison of predicted and measured maximum and minimum flow of the models from 2016 to 2019

年份/年	实测流量/( $\text{m}^3 \cdot \text{s}^{-1}$ )		最大流量预测/( $\text{m}^3 \cdot \text{s}^{-1}$ )			最小流量预测/( $\text{m}^3 \cdot \text{s}^{-1}$ )		
	最大值	最小值	LSTM	GRU	LSTM-GRU	LSTM	GRU	LSTM-GRU
2016	257	0	180	141	211	-0.14	-0.68	0.30
2017	35	0	11	14	11	-0.01	-0.91	0.25
2018	44	0	53	51	51	-0.34	-1.29	-0.02
2019	9	0.30	7	5	7	0.02	-0.81	0.18
绝对误差平均值/( $\text{m}^3 \cdot \text{s}^{-1}$ )	—	—	29.75	37	19.75	0.19	0.85	0.17

## 4 结论

本文选取东茨村水文站2006—2019年水文数据资料,利用LSTM-GRU复合模型对河流流量进行预测。主要结论如下:

(1)无论在训练期还是验证期,LSTM与GRU预测精度相差不大,LSTM-GRU复合模型预测精度整体上高于单一的LSTM或GRU模型。在流量高低值预测上,LSTM-GRU复合模型的预测效果同样优于单一的LSTM或GRU模型。可以说,LSTM-GRU复合模型预测更稳定,精度更高,模拟效果更好。

(2)时序步长是深度学习模型中的一个重要参数,它反映出水文过程的产流机制。在本文所建议的三个模型中,时序步长为6天,说明白沟河流域在水文气象因子对河流汇流过程的影响具有时间滞后效应,也就是说,6天内的水文气象因子对河流具有明显影响,6天以外的水文气象因子对河流流量的影响不显著。

(3)降水作为一个最为重要的水文气象因子是一个稀疏时间序列,具体地说大部分是0值,偶尔有一个降水量值。通过降水稀疏时间序列进行移动平均能够更加准确地模拟预测河流流量。本文的三个模型在训练期与验证期中,移动平均时长为12天时,三个模型平均预测精度达到最高,能够真实地反映白沟河流域降水汇流的时间特征。

### 参考文献:

[1] 赵力学,黄解军,程学军,等.基于VMD-BP模型的河流流量预测方法[J].长江科学院院报,2020,37(7):47-52.  
 [2] 刘志雨,侯爱中,王秀庆.基于分布式水文模型的中小河流洪水预报技术[J].水文,2015(1):1-6.  
 [3] ÖZLEM T, ERGIN G. Forecasting of monthly river flow with autoregressive modeling and data-driven techniques[J]. Neural Computing & Applications, 2014, 25(1):179-188.

[4] 陈东男.河流径流中长期预测方法概述[J].中国水运(下半月),2015,15(5):176-177.  
 [5] ZAREMBA W, SUTSKEVER I, VINVALS O. Recurrent Neural Network Regularization[J]. Eprint Arxiv, 2014.  
 [6] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8).  
 [7] CHO K, MERRIENBOER B V, GULCEHRE C. et al. Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation[J]. Computer Science, 2014.  
 [8] AN L, HAO Y, YEHT C J, et al. Simulation of karst spring discharge using a combination of time-frequency analysis methods and long short-term memory neural networks[J]. Journal of Hydrology, 2020, 589.  
 [9] AYZEL G, HEISTERMANN M. The effect of calibration data length on the performance of a conceptual hydrological model versus LSTM and GRU: A case study for six basins from the CAMELS data period [J]. Computers & Geosciences, 2021.  
 [10] 杨军.清河水库中长期水文预报方法研究及系统开发[D].沈阳:沈阳农业大学,2016.  
 [11] 王雨晴.基于LSTM的多模型水文径流预测方法的研究[D].天津:天津大学,2019.  
 [12] ZHANG X, JIN J, LAN Z, Et al. ICENET: A semantic segmentation deep network for river ice by Fusing Positional and Channel-Wise Attentive Features [J]. Remote Sensing, 2020, 12(2).  
 [13] CHUNG J, GULCEHRE C, CHO K H, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling [J]. Eprint Arxiv, 2014.  
 [14] 王彦梅.基于移动平均法的汽车4S店新车销售需求预测分析[J].中国商论,2019(18):58-59.  
 [15] 刘帅.高维稀疏数据的相关性度量方法研究[D].北京:首都经济贸易大学,2014.  
 [16] 孙德升.水文预报方案精度评定和检验标准综述[J].黑龙江水利科技,2014,42(6):30-32.  
 [17] 李硕,沈占锋,刘克俭,等.大清河流域土地利用变化的地形梯度效应分析[J].农业工程学报,2021,37(5):275-284.  
 [18] BENGIO Y. Learning Deep Architectures for AI[J]. Foundations & Trends in Machine Learning, 2009, 2(1):1-127.  
 [19] 顾逸.基于长短期记忆循环神经网络及其结构约减变量的中长期径流预报研究[D].武汉:华中科技大学,2018.

## The LSTM-GRU Combinatorial Model of Deep Learning and Its Application to Hydrological Simulations

LU Guanyu<sup>1,2</sup>, LIU Wenqiang<sup>1,2</sup>, HAO Huiqing<sup>1,2</sup>, WANG Qi<sup>3</sup>, HAO Yonghong<sup>2</sup>

1. College of Geography and Environmental Sciences, Tianjin Normal University, Tianjin 300387, China;
2. Tianjin Key Laboratory of Water Resources and Environment, Tianjin Normal University, Tianjin 300387, China;
3. College of Mathematical Science, Tianjin Normal University, Tianjin 300387, China)

**Abstract:** Recursive neural networks (RNN) with long and short-term memory (LSTM) or gated cycle units (GRU) are deep neural networks suitable for time series, each of which has respective advantages and disadvantages. In this paper, in order to make up for their respective deficiencies and improve the prediction accuracy of river flow, the LSTM-GRU combination model is established and applied to the Baigou River basin of Daqing River system of Haihe River Basin. Based on the daily observation data of Dongci Village Hydrological Station from 2006—2019, the LSTM-GRU hydrological model was established with the observation data of 8 hydrometeorological factors (air pressure, water temperature, relative humidity, precipitation, sunshine, ground temperature, wind speed and water level) as the input and the river flow as the output. To verify the model advantages, the simulation results of LSTM-GRU were compared with those of LSTM and GRU, respectively. The results show that the stability and accuracy of the LSTM-GRU combination model are significantly better than the single LSTM with GRU model, providing a better tool for river flow prediction.

**Keywords:** deep learning; LSTM; GRU; moving average; flow prediction

---

(上接第44页)

## Research and Application of a Total Variation Diminishing Scheme to Improve the Stability and Efficiency of Channel Routing

ZANG Shuaihong, LI Zhijia, DU Ruoyu

(College of Hydrology and Water Resources, Hohai University, Nanjing 210098, China)

**Abstract:** Non-physical oscillation, negative flow or overshoot often occur when using some river flood routing methods due to the rapid change of flood wave in a short time. This study introduced a TVD limiter into Muskingum-Cunge-Todini (MCT) method, to guarantee the “total variation diminishing” (TVD) of the numerical solution, so as to improve the robustness of MCT method. The TVD, first-order versions and second-order versions of MCT were implemented in the XAJ-DCH model and applied in Tunxi catchments. Compared with the second-order version of MCT, the TVD and first-order versions of MCT are more robust and can achieve the similar simulation accuracy with the second-order version of MCT. In addition, the original model needs 200s as the time step of channel routing to remain numerical stability in flood No.1996060100, after the introduction of TVD and first-order versions of MCT method, the time step of river routing can be extended to 3600s. Therefore, its run time can be shortened from about 3min to about 1min.

**Keywords:** TVD; Channel routing; MCT; XAJ-DCH model