

山区流域GRU神经网络洪水预报模型研究

金保明¹, 司琪¹, 陈朝清², 程滕龙¹, 徐澄慧¹

¹福州大学土木工程学院, 福建 福州

²浙江省水利水电勘测设计院有限责任公司, 浙江 杭州

收稿日期: 2025年9月24日; 录用日期: 2025年10月30日; 发布日期: 2025年12月26日

摘要

运用具有更新门和重置门控制的深度学习循环神经网络(GRU)技术, 选取1997~2021年期间崇阳溪上游流域29场降雨径流过程, 其中21场过程作为训练集, 以上游岚谷等6个雨量站逐时雨量和下游控制断面武夷山水文站前期流量为输入, 以该断面相应流量为输出, 依据RMSE最小方法确定网络隐含层单元数和迭代轮数, 在GRU层之后增加全连接层, 并对其进行Dropout化处理, 构建GRU神经网络预报模型。采用该模型对余下的8场洪水进行测试, 并与共轭梯度PRPB神经网络模型结果进行对比。结果表明, GRU模型预测效果更好, 其洪水过程预测误差均小于PRPB模型, 在洪峰流量预测精度方面总体上略高于PRBP模型, 模型的纳什效率系数也比后者高, 因此适合用于山区流域的洪水预报。

关键词

GRU神经网络, 深度学习, 洪水预报, 崇阳溪流域

Study on GRU Neural Network Flood Forecasting Model in Mountain Watershed

Baoming Jin¹, Qi Si¹, Chaoqing Chen², Tenglong Cheng¹, Chenghui Xu¹

¹College of Civil Engineering, Fuzhou University, Fuzhou Fujian

²Zhejiang Design Institute of Water Conservancy and Hydro-Electric Power Co., Ltd., Hangzhou Zhejiang

Received: September 24, 2025; accepted: October 30, 2025; published: December 26, 2025

Abstract

The deep learning recurrent neural network technology with renewal gate and reset gate control (GRU) was used to select 29 rainfall runoff processes in the upper reaches of Chongyangxi River from 1997 to 2021, among which 21 floods were selected as the training set. Hourly precipitation records from six upstream

作者简介: 金保明, 男, 博士, 高级工程师, 研究方向为水文水资源, Email: jbm720@126.com

文章引用: 金保明, 司琪, 陈朝清, 程滕龙, 徐澄慧. 山区流域 GRU 神经网络洪水预报模型研究[J]. 水资源研究, 2025, 14(6): 577-589. DOI: 10.12677/jwrr.2025.146063

rain gauges—Langu among them—together with the antecedent discharge measured at the downstream Wuyishan station were employed as model inputs. Taking the corresponding flow of this section as the model output, the root-mean-square error minimum criterion was used to analyze the number of hidden layer units and the number of network iteration rounds. At the same time, a full-connection layer was set after the GRU layer and the full-connection layer was processed by Dropout to construct a GRU neural network model for mountain watershed. The model was used to test the remaining 8 floods and compared with the artificial neural network PRPB model. The results show that the GRU model performs better in prediction, and its flood process prediction error is smaller than that of PRPB model, and the accuracy of flood peak flow prediction is slightly higher than that of PRBP model. The Nash efficiency coefficient of the model is also higher than that of the latter, so it is suitable for flood forecasting in mountain basins.

Keywords

GRU Neural Network, Deep Learning, Flood Forecast, Chongyang River Basin

Copyright © 2025 by author(s) and Wuhan University & Bureau of Hydrology, Changjiang Water Resources Commission. This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

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



Open Access

1. 引言

在山区流域的防洪减灾工作中,洪水预报发挥着极为重要的作用;对于防汛部门而言,迅速而准确的洪水预报,是防汛预警和调度的关键依据。除了采用常规方法外,构建循环神经网络(Recurrent Neural Networks, RNN)用于洪水预报[1],可以满足上述需求。近年来,循环神经网络因其设计结构适合模拟时间序列相关数据,被广泛用于径流预测研究[2]。然而,普通 RNN 模型在学习长时间序列时,存在梯度消失问题。为此,Cho 等人提出了门控制循环单元神经网络(Gated Recurrent Unit, GRU) [3]。在水文预报领域,基于 GRU 的研究正成为热点。GRU 是一种对长短期记忆网络(Long Short-Term Memory, LSTM)变体的优化[4]:其将 LSTM 中的遗忘门与输入门进行合并,形成单一的更新门,同时保留重置门;网络没有设置记忆状态变量,而是将输出结果作为记忆状态不断向后循环传递。相较于 LSTM 网络,GRU 网络能在达到同样效果的基础上降低训练难度,提升模型效率[5]。

近年来,已有研究从正则化约束[6]、记忆-滞后协同[7]到多预处理对比[8]三个层面持续拓展 GRU 的适用边界。还有许多学者在智能算法耦合层面,例如:以改进灰狼算法(IGWO)自动搜索 GRU 超参数[9]、以改进麻雀搜索算法(ISSA)同步优化 CNN-LSTM 与 GRU 双支路[10]等,展示了“群体智能+混合结构”的巨大潜力。区域验证方面,顾逸[11]简化了 GRU 结构提出的 Simple-LSTM 把长江上游中长期预报效率提高 30%; De Melo G 等[12]证实 GRU 与 LSTM 精度相当却省时一半; Gao 等[13]采用 GRU 和 LSTM 两种递归网络对沙溪渔潭站短期径流进行预测,对于 3 h 预见期将洪峰误差压低 5%;郭玉雪等[14]发现 GRU 对舟山台风非平稳入流预测,其纳什系数仍保持 0.90; Khatun 等[15]采用 CNN-GRU 模型在印度马哈纳迪河季风高峰流量模拟中精度提升 15%。综上,GRU 已沿“正则化-杂交-混合”路径在多流域、多尺度验证其稳健性,为崇阳溪上游山区流域应用奠定方法论基础。

考虑到前人的研究多聚焦于模型参数率定、模型在平原区或丘陵区流域的应用,GRU 模型在山区源头流域洪水过程模拟研究中应用实例不多,论文以崇阳溪上游流域为例,利用 29 场暴雨洪水过程,构建以 6 个雨量站逐时降水与武夷山水文站前期流量为输入、未来相应流量为输出的山区源头流域 GRU 网络洪水预报模型;并与传统 PRBP 模型进行对比,验证其在洪峰流量、峰现时间、洪水过程预报误差上的优势,为山区源头流域提供“仅依赖雨量及流量数据”的数据驱动洪水预报模型。该模型功能简单适用,运算速度快,泛化能力较好,可

以提升基层防御洪水的时效性与可操作性，为流域防洪减灾工作提供服务。

2. GRU 网络结构和算法

2.1. GRU 基本构架

与标准 RNN 相比，GRU 通过引入门控机制，能够更有效地捕捉长距离依赖关系，提升模型的表现和训练效果[16]。GRU 网络整体结构见图 1：




图 1. GRU 神经网络整体结构

2.2. 门控制循环单元结构及其算法

图 2 为 GRU 门控制循环单元内部结构，其中重置门和更新门是 GRU 中的关键组件。重置门决定过去信息对当前状态的影响程度，而更新门控制了新信息和旧信息的融合程度。借助其门控机制的协同作用，GRU 能够高效捕捉序列数据中的长期依赖关系。在模型架构上，GRU 相较于 LSTM 更为简洁，这使得其在训练过程中展现出更快的速度[17]。

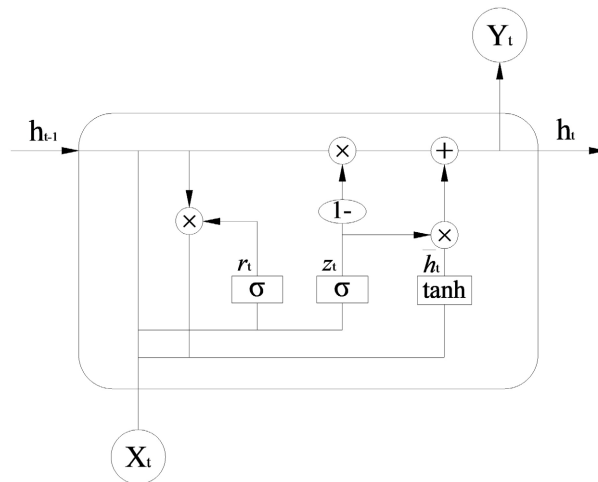


图 2. GRU 门控制循环单元内部结构

首先，单元将通过当前时间步输入信息 x_t 和前一时间步单元输出信息 h_{t-1} 来获取两个门结构的控制状态。GRU 网络中的更新门负责对先前存储的信息进行控制，即决定模型 $t-1$ 时刻和 t 时刻有多少信息继续传递至 $t+1$ 时刻。 z_t 为更新门的控制信息矩阵，其计算式如下：

$$z_t = \sigma[W_z(h_{t-1}, x_t) + b_z] \quad (1)$$

式中： σ 为 Sigmoid 激活函数； W_z 为更新门权值矩阵； b_z 为更新门偏置矩阵。

GRU 的另一个门结构称为重置门, 它的主要功能在于调控当前输入信息与之前状态之间的关联性。其状态决定了先前状态对当前状态更新过程中的影响程度。 r_t 为重置门的控制信息矩阵, 其计算式如下:

$$r_t = \sigma[W_r(h_{t-1}, x_t) + b_r] \quad (2)$$

式中: W_r 为重置门权值矩阵; b_r 为重置门偏置矩阵。

网络计算出两个信息矩阵后, 通过信息矩阵 r_t 来重置前一时间步的单元隐含状态 h_{t-1} , 然后和当前时间步 x_t 相衔接, 通过状态激活函数将数值范围调整至 $[-1, 1]$:

$$\tilde{h}_t = \tanh[W_h(r_t \odot h_{t-1}, x_t) + b_h] \quad (3)$$

式中: W_h 为权值矩阵; b_h 为偏置矩阵。这里得到的 \tilde{h}_t 为候选隐状态矩阵, 负责记录 t 时的“单元状态”。

“更新记忆”阶段中, 更新门 z_t 控制了当前状态 h_t 是如何结合过去的状态 h_{t-1} 和候选状态 \tilde{h}_t 的:

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (4)$$

式中: $z_t \odot \tilde{h}_t$ 则负责记录候选隐状态矩阵 \tilde{h}_t 中对网络学习产生正面影响的部分内容, 由更新门控制矩阵 z_t 负责筛选。最终得到的 h_t 将通过输出层函数转化为实际需求的模型预测结果 y_t 。计算式如下:

$$y_t = f(W_y h_t + b_y) \quad (5)$$

式中: W_y 为输出层权值矩阵; b_y 为输出层偏置矩阵。

3. 山区流域 GRU 神经网络洪水预报模型构建

3.1. 流域概况

选择崇阳溪源头(上游)流域进行研究, 其控制流域面积 1078 km²。利用 Thiessen polygon 法对流域进行子单元划分, 推求各子单元面积权重, 同时分析各单元净雨到武夷山站的汇流时间, 详见图 3、表 1。

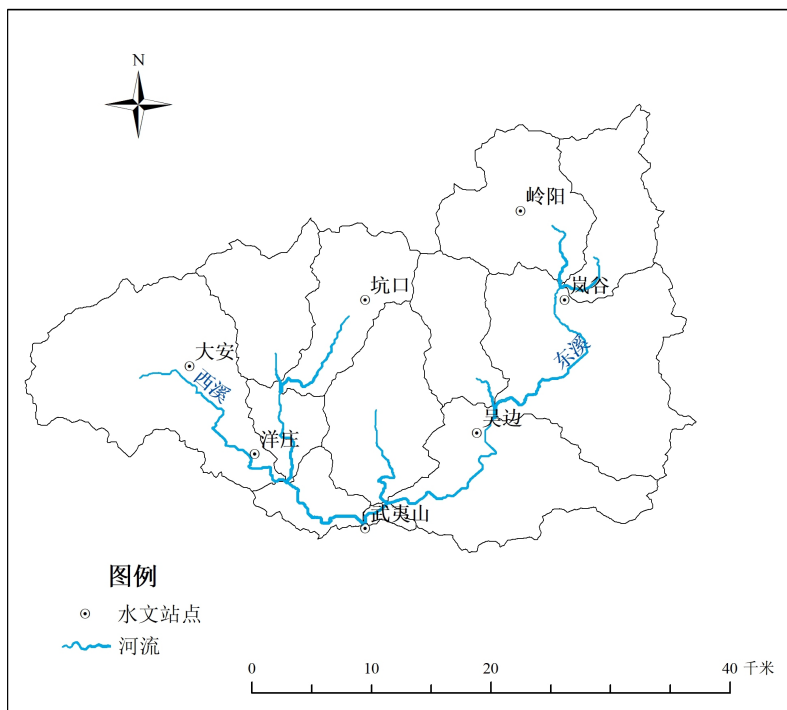


图 3. 崇阳溪上游流域水系图

表 1. 各子流域单元面积权重及汇流时间统计表

水文站点	武夷山	洋庄	吴边	大安	坑口	岭阳	岚谷
面积(km ²)	66.2	90.7	218.2	202.3	165.8	139.9	190.5
权重 λ	0.06	0.08	0.20	0.19	0.15	0.13	0.18
汇流时间(h)	-	1	1.5	2.5	3	3	4

3.2. 样本数据处理

论文以 1997~2021 年崇阳溪源头流域的 29 场暴雨洪水过程为基础[18], 选取 21 场洪水资料为训练样本, 8 次洪水为测试样本。

1) 同步化处理

由于 GRU 网络对数据具有记忆功能, 因此需要考虑汇流时间、将不同站点雨量数据进行同步化处理。

$$X_i(t) = P_i(t - \tau_i) \quad (6)$$

式中: $X_i(t)$ 为第 i 个雨量站 t 时段经同步化处理后对应的模型输入序列, $P_i(t)$ 为第 i 个雨量站 t 时段的雨量, τ_i 为相应的汇流时间, 具体取值如表 1 所示。经处理后的雨量数据对武夷山站而言在时间尺度上实现了同步, 适应实际预报的需求。

2) 零数据处理

流域退水过程中会有相当数量的零输入降雨, 若不进行处理, 将导致模型中出现相互矛盾的信息, 从而造成模型输出的混乱[19]。采用 K. C. Luk 等学者的公式[20]进行转换:

$$X(t) = a \log_{10}(x(t) + b) \quad (7)$$

式中: $x(t)$ 为初始数据, $X(t)$ 为去零化后的数据; a 、 b 为可变参量。

3) 标准化处理

模型输入包括雨量(单位: mm)和流量(单位: m³/s)两类数据。为了便于网络学习, 需要对数据进行标准化处理。采用式(8)进行转换:

$$X(t) = (x(t) - \mu) / \sigma \quad (8)$$

式中: $x(t)$ 为标准化之前的数据; μ 为序列均值; σ 为序列标准差; $X(t)$ 为标准化之后的数据。以此构建输入向量, 作为驱动数据输入循环网络模型。为得到实际预测流量, 训练好网络后, 输出的结果需进行反标准化:

$$x(t) = X(t) \sigma + \mu \quad (9)$$

3.3. 模型构建

选择洋庄等 6 个雨量站的逐时降雨量和武夷山站前期流量组成向量为输入, 武夷山站后期对应流量为输出, 构建 GRU 网络预报模型, 图 4 为模型结构。

输入层公式:

$$\begin{cases} X_j(t) = \{a \log_{10}[\lambda_j P_j(t - \tau_j) + b] - \mu_{pj}\} / \sigma_{pj}, j = 1, 2, \dots, 6 \\ X_7(t) = [Q_r(t-1) - \mu_q] / \sigma_q \\ X(t) = [X_1(t), X_2(t), \dots, X_7(t)]^T \end{cases} \quad (10)$$

式中: $a = 0.5$ 、 $b = 1$; λ_j 分别为 6 个子流域单元面积权重(见表 1 取值); μ_{pj} 为第 j 个雨量站雨量过程序列均

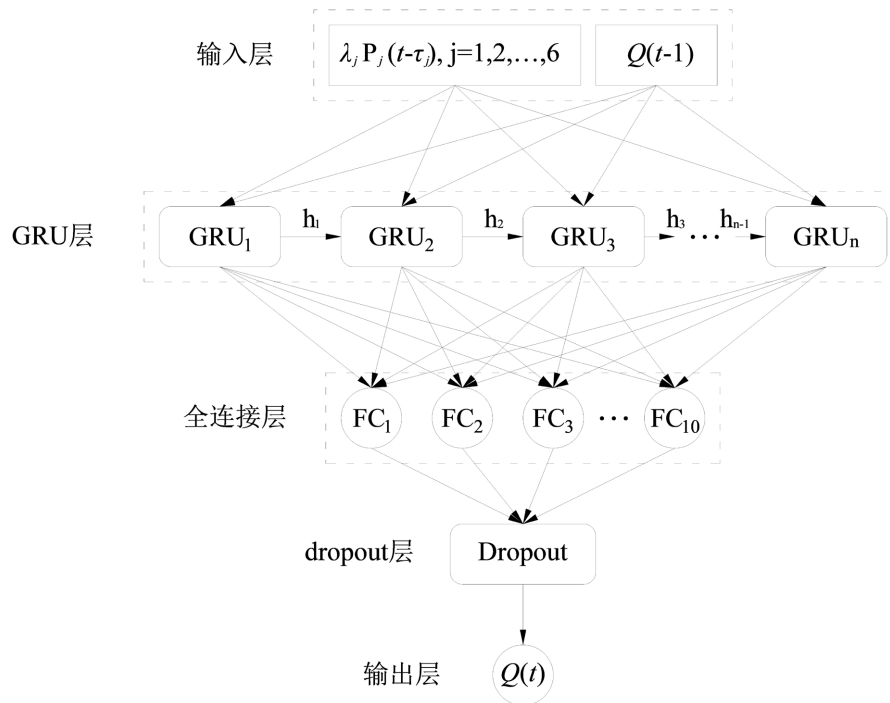


图 4. 山区流域 GRU 神经网络洪水预报模型结构

值、 σ_{pj} 为雨量过程序列对应的标准差； μ_q 为武夷山站实测流量过程序列均值、 σ_q 为流量过程序列对应的标准差； $P_j(t-\tau_j)$ 为上游洋庄等 6 个雨量站逐时雨量； $Q_r(t-1)$ 为武夷山站前 1 h 流量 $Q_r(t-1)$ ； $\mathbf{X}(t)$ 为经该层预处理后转化为 GRU 层的输入信息矩阵。

GRU 层公式：

$$\begin{cases} z(t) = \sigma[\mathbf{W}_{xz}\mathbf{X}(t) + \mathbf{W}_{hz}\mathbf{h}(t-1) + \mathbf{b}_z] \\ r(t) = \sigma[\mathbf{W}_{xr}\mathbf{X}(t) + \mathbf{W}_{hr}\mathbf{h}(t-1) + \mathbf{b}_r] \\ \tilde{\mathbf{h}}(t) = \tanh\{\mathbf{W}_x\mathbf{X}(t) + \mathbf{W}_h[r(t) \odot \mathbf{h}(t-1)] + \mathbf{b}\} \\ \mathbf{h}(t) = [\mathbf{1} - z(t)] \odot \mathbf{h}(t-1) + z(t) \odot \tilde{\mathbf{h}}(t) \end{cases} \quad (11)$$

在 t 时刻，GRU 层单元的输入信息包括：① $t-1$ 时刻 GRU 单元输出的处理后的流量信息矩阵 $\mathbf{h}(t-1)$ ；② 当前输入信息矩阵 $\mathbf{X}(t)$ 。通过更新门与重置门处理后，模型得以筛除导致损失函数增大的冗余信息，并保留对预测精度具有正向增益的有效信息；随后，单元状态完成更新，进而输出当前时刻武夷山水文站的流量信息 $\mathbf{h}(t)$ 。

全连接层公式：

$$y_i(t) = \sigma\left(\sum_{k=t-n}^n \mathbf{W}_{yk}\mathbf{h}(k) + \mathbf{b}_{yk}\right) \quad (12)$$

式中： \mathbf{W}_{yk} 与 \mathbf{b}_{yk} 分别对应整合过程中权值矩阵和偏置值矩阵； $y_i(t)$ 表示全连接层在时间步 t 的输出，其数值由 GRU 层单元在该时刻的隐藏状态矩阵 $\mathbf{h}(k)$ 经线性运算后获得； σ 为激活函数。

为提高模型的泛化能力并降低网络过拟合风险，对全连接层进行 Dropout 化处理，抛弃因子设为 10%。在 dropout 层中设置 0 和 1 组成 10×1 随机数矩阵，以抛弃冗余信息，其公式为：

$$Y(t) = \text{dropout}\left[\sum_{i=1}^{10} y_i(t)\right] \quad (13)$$

式中: $Y(t)$ 为模型输出信息。

输出层公式:

$$Q(t) = \sigma_q Y(t) + \mu_q \quad (14)$$

t 时刻预测流量值 $Q(t)$ 由输出层去标准化得到。

3.4. 参数率定

在模型训练过程中, 设置不同的 GRU 层单元数和网络迭代次数并通过计算得到训练样本 21 场洪水模型输出值均方根误差 RMSE 的平均值如表 2 所示, 同时绘制三维曲面图 5、二维等值线图 6。模型学习率取 0.01。

通过表 2 以及三维曲面图 5 和二维等值线图 6 可知, 在 GRU 层单元数为 32, 网络迭代轮数为 100 的情况下, 存在最小均方误差。至此, GRU 网络洪水预报模型的构建得以完成。

表 2. 不同 GRU 层单元数和网络迭代轮数情况下训练样本 RMSE 均值表

RMSE		隐含层单元数(Hidden units)					
		8	16	32	64	128	256
网络迭代次数(epochs)	50	105.8	98.6	96.8	91.5	90.1	91.7
	100	94.7	90.7	85.2	90.5	94.3	96.6
	150	94.5	91.4	92.9	95.1	100.8	98.6
	200	92.5	96.5	93.0	104.8	106.2	106.9
	250	93.6	94.2	93.8	109.3	108.4	106.6
	300	94.8	106.6	102.7	106.2	105.2	104.5




图 5. RMSE 随 GRU 层单元数和网络迭代轮数变化三维曲面图





图 6. RMSE 随 GRU 层单元数和网络迭代轮数变化等值线图


3.5. 模型测试

采用流域 8 场洪水过程对模型进行测试，得到洪水流量预报过程线图，详见图 7。同时构建共轭梯度 PRBP 洪水预测模型[21]与 GRU 模型进行对比。表 3 为洪水流量过程预报误差分析表，表 4 为洪峰流量误差分析表。


从洪水预报过程来看，表 3 中除“2019-07-05”洪水过程平均相对误差为 13.6%外，其余 7 场洪水过程的误差均在 10% 以内，所有洪水过程平均相对误差均比 PRBP 模型小。GRU 模型预报的 8 场洪水纳什效率系数大于 0.920，均比 PRBP 模型高。表明 GRU 模型对洪水流量的变化展现出较高敏感性，意味着其能够有效掌握洪水演变过程中的主要趋势。




(a) “1998-06-14” 洪水




(b) “2003-06-25”洪水




(c) “2006-06-14”洪水




(d) “2008-07-19”洪水




(e) “2019-07-05”洪水



(f) “2019-07-09”洪水



(g) “2021-06-28”洪水



(h) “2021·06·30”洪水

图 7. 崇阳溪上游流域 8 场洪水预报过程线

表 3. 8 场洪水流量过程预报误差分析表(单位: m^3/s , %)

时间	GRU 模型					PRBP 模型				
	流量过程 ΔQ		流量过程 $\Delta Q / Q_{\text{实测}}$		NSE	流量过程 ΔQ		流量过程 $\Delta Q / Q_{\text{实测}}$		NSE
	最大值	平均值	最大值	平均值		最大值	平均值	最大值	平均值	
1998-06-14	267	64.3	31.1	6.7	0.966	-273	74.2	68.0	12.6	0.941
2003-06-25	83	13.5	-30.9	9.1	0.958	103	15.7	54.6	10.8	0.942
2006-06-14	-81	11.5	27.7	4.6	0.954	-97	14.9	-40.8	9.6	0.939
2008-07-19	-96	32.3	-26.2	5.1	0.972	167	35.5	38.4	7.1	0.964
2019-07-05	203	36.2	47.6	13.6	0.928	-205	41.4	54.9	17.1	0.905
2019-07-09	98	24.7	21.5	3.8	0.987	-102	34.0	-34.6	5.6	0.974
2021-06-28	-164	29.6	-31.1	7.6	0.933	-182	38.6	-65.8	11.4	0.877
2021-06-30	-157	53.5	-32.1	5.5	0.937	-154	64.6	62.8	11.7	0.918

备注: $\Delta Q = Q_{\text{预报}} - Q_{\text{实测}}$ 。

表 4. 8 场洪水洪峰流量预报误差分析表(单位: m^3/s , %, hour: min)

时间	主次峰型	$Q_{\text{实测}}$	GRU 模型				PRBP 模型			
			$Q_{\text{预报}}$	ΔQ	$\Delta Q / Q_{\text{实测}}$	$\Delta T_{\text{洪峰}}$	$Q_{\text{预报}}$	ΔQ	$\Delta Q / Q_{\text{实测}}$	$\Delta T_{\text{洪峰}}$
1998-06-14	主峰	3080	3178	98	3.20	0:36	3017	-63	-2.00	0:36
1998-06-14	次峰	2710	2718	8	0.30	0:00	2551	-159	-5.90	1:00
2003-06-25	主峰	797	829	32	4.10	-0:24	806	9	1.20	-0:24
2006-06-14	主峰	737	779	42	5.70	1:00	730	-7	-1.00	1:00
2008-07-19	主峰	2172	2111	-61	-2.80	0:00	2211	39	1.80	1:00
2019-07-05	主峰	1830	1968	138	7.50	0:20	1654	-176	-9.60	0:40

续表

2019-07-05	次峰	798	793	-5	-0.60	0:00	774	-24	-3.00	2:00
2019-07-09	主峰	2770	2711	-59	-2.10	-0:20	2755	-15	-0.50	0:40
2021-06-28	主峰	1700	1805	105	6.20	0:45	1618	-82	-4.80	0:45
2021-06-28	次峰	938	888	-50	-5.30	1:00	833	-105	-11.20	1:00
2021-06-30	主峰	1237	1188	-49	-4.00	0:20	1251	14	1.20	-1:40
2021-06-30	次峰	1150	1156	6	0.50	0:15	1007	-143	-12.50	0:15
平均值	-	-	-	54.4	3.53	0:25	-	0:27	4.56	0:55

备注： $\Delta T_{\text{洪峰}} = T_{\text{预报}} - T_{\text{实测}}$ ，最后一行为各指标绝对值的平均值。

从预报洪峰流量来看，由表 4 可知，8 场洪水的洪峰流量绝对误差总体较小，平均值为 $54.4 \text{ m}^3/\text{s}$ ，最大值为 $138 \text{ m}^3/\text{s}$ （“2019-07-09”洪峰）；其相对误差也较小，平均值为 3.53%，最大值为 6.9%（“2019-07-09”洪峰）。PRBP 模型预测的洪峰流量的误差也较小。总体上 GRU 模型在洪峰流量预测精度方面略高于 PRBP 模型。

洪峰出现时间方面，GRU 模型平均误差为 25 min，仅为 PRBP 模型(55 min)的 45%，二者虽均在许可误差之内，但 GRU 模型误差相比较更小，稳定性更佳。两模型均呈“总体偏晚”的倾向，但 GRU 偏差分布更集中，优于 PRBP。

4. 结语

通过选取具有可靠性、代表性、一致性的训练和测试样本，并结合崇阳溪源头山区流域实际情况拟定网络结构，依据均方根误差 RMSE 最小方法确定 GRU 网络迭代轮数为 100、隐含层单元数为 32，紧接该层之后增加一个全连接层，然后对其进行 Dropout 化处理，建立基于 GRU 网络的洪水预报模型。同时构建基于 PRBP 的预报模型进行比较。

1) GRU 与 PRBP 模型的预报结果表明，两种模型的精度均符合规范要求，相对来说具有更新门和重置门深度学习功能的 GRU 模型预测效果更好，模型的纳什效率系数比 PRBP 模型高；其洪水过程预测误差均小于 PRBP 模型，在洪峰流量及峰现时间的预测精度方面总体上略高于后者，因此可以满足山区源头流域的洪水预报的需求。

2) 在 GRU 层之后增加全连接层，并对其进行 Dropout 化处理，有利于优化 GRU 隐含层单元数和网络迭代轮数，同时可以提高模型的泛化能力并降低网络过拟合风险。

基金项目

福建省自然科学基金项目(2023J01405)；福建省水利科技资金项目(MSK202408)。

参考文献

[1] ELMAN, J. L. Finding structure in time. Cognitive Science, 1990, 14(2): 179-211. https://doi.org/10.1207/s15516709cog1402_1

[2] ZHANG, J., CHEN, X., KHAN, A., et al. Daily runoff forecasting by deep recursive neural network. Journal of Hydrology, 2021, 596(5): 126067-126076. <https://doi.org/10.1016/j.jhydrol.2021.126067>

[3] CHO, K., VAN MERRIENBOER, B., GULCEHRE, C., et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation. Computer Science, 2014, 1: 1165-1179. <https://doi.org/10.3115/v1/d14-1179>

[4] MAHJOUB, S., CHRIFI-ALAOUI, L., MARHIC, B., et al. Predicting energy consumption using LSTM, multi-layer GRU and Drop-GRU neural networks. Sensors, 2022, 22(11): 4062-4081. <https://doi.org/10.3390/s22114062>

[5] 李扬帆, 张凌浩, 雷勇, 等. 基于时间卷积网络和门控循环单元的短期用电量预测方法[J]. 水电能源科学, 2021, 39(8): 198-201+173.

- [6] 段生月, 王长坤, 张柳艳. 基于正则化 GRU 模型的洪水预测[J]. 计算机系统应用, 2019, 28(5): 196-201.
- [7] ZHANG, Y., ZHOU, Z., VAN GRIENSVEN THÉ, J., et al. Flood forecasting using hybrid LSTM and GRU models with lag time preprocessing. *Water (Switzerland)*, 2023, 15(22): 3982-3999. <https://doi.org/10.3390/w15223982>
- [8] WANG, W., DU, Y., CHAU, K., et al. Evaluating the performance of several data preprocessing methods based on GRU in forecasting monthly runoff time series. *Water Resources Management*, 2024, 38(9): 3135-3152. <https://doi.org/10.1007/s11269-024-03806-y>
- [9] ZHAO, X. H., LV, H. F., WEI, Y. Z., et al. Streamflow forecasting via two types of predictive structure-based gated recurrent unit models. *Water*, 2021, 13(1): 91-107. <https://doi.org/10.3390/w13010091>
- [10] VATANCHI, S. M., ETEMADFARD, H., MAGHREBI, M. F., et al. A comparative study on forecasting of long-term daily streamflow using ANN, ANFIS, BiLSTM and CNN-GRU-LSTM. *Water Resources Management*, 2023, 37(12): 4769-4785. <https://doi.org/10.1007/s11269-023-03579-w>
- [11] 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]: [硕士学位论文]. 武汉: 华中科技大学, 2018.
- [12] DE MELO, G., SUGIMOTO, D., TASINAFFO, P., et al. A new approach to river flow forecasting: LSTM and GRU multivariate models. *IEEE Latin America Transactions*, 2019, 17(12): 1978-1986. <https://doi.org/10.1109/ila.2019.9011542>
- [13] GAO, S., HUANG, Y., ZHANG, S., et al. Short-term runoff prediction with GRU and LSTM networks without requiring time step optimization during sample generation. *Journal of Hydrology*, 2020, 589(10): 125188-125198. <https://doi.org/10.1016/j.jhydrol.2020.125188>
- [14] 郭玉雪, 许月萍, 陈浩, 等. 基于多种递归神经网络的海岛水库径流预报[J]. 水力发电学报, 2021, 40(9): 14-26.
- [15] KHATUN, A., NISHA, M. N., CHATTERJEE, S., et al. A novel insight on input variable and time lag selection in daily streamflow forecasting using deep learning models. *Environmental Modelling & Software*, 2024, 179(8): 106126-106141. <https://doi.org/10.1016/j.envsoft.2024.106126>
- [16] GHAREHBAGHI, A., GHASEMLOUNIA, R., AHMADI, F., et al. Groundwater level prediction with meteorologically sensitive gated recurrent unit (GRU) neural networks. *Journal of Hydrology*, 2022, 612(3): 128262-128273. <https://doi.org/10.1016/j.jhydrol.2022.128262>
- [17] 金保明, 曾泓源, 卢旺铭, 等. 基于 LSTM 的山区流域洪水预报模型研究[J]. 西南大学学报(自然科学版), 2025, 47(5): 177-187.
- [18] 杜伦阅. 山区流域 BP 神经网络降雨径流预报模型研究[D]: [硕士学位论文]. 福州: 福州大学, 2019.
- [19] NASSERI, M., ASGHARI, K. and ABEDINI, M. J. Optimized scenario for rainfall forecasting using genetic algorithm coupled with artificial neural network. *Expert Systems with Applications*, 2007, 35(3): 1415-1421. <https://doi.org/10.1016/j.eswa.2007.08.033>
- [20] LUK, K. C., BALL, J. E. and SHARMA, A. A study of optimal model lag and spatial inputs to artificial neural network for rainfall forecasting. *Journal of Hydrology*, 2000, 227(1-4): 56-65. [https://doi.org/10.1016/S0022-1694\(99\)00165-1](https://doi.org/10.1016/S0022-1694(99)00165-1)
- [21] 司琪, 金保明, 卢旺铭, 等. 崇阳河流域 PRBP 神经网络洪水预报模型研究[J]. 人民珠江, 2025, 46(6): 68-74.