

DOI: 10.13718/j.cnki.xdzk.2025.05.015

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.

基于 LSTM 的山区流域洪水预报模型研究

金保明¹, 曾泓源¹, 卢旺铭², 陈朝清¹, 康顺¹

1. 福州大学 土木工程学院, 福州 350108; 2. 南平市水旱灾害防御中心, 福建 南平 354200

摘要: 山区流域洪水具有突发性强、预见期短的特点, 快速准确进行洪水预报始终是防汛工作的关键问题。以长短期记忆深度学习神经网络技术为基础, 选取崇阳溪流域 1997 年到 2022 年共 30 场暴雨洪水过程作为研究数据, 将其中 21 场洪水作为训练集, 以上游吴边等 6 个雨量站的逐时雨量、武夷山站控制断面前期流量为模型输入, 武夷山站控制断面相应洪水流量为模型输出, 采用均方根误差最小准则分析确定 LSTM 隐含层单元数和网络迭代轮数, 同时在 LSTM 层之后设置一个全连接层, 并对全连接层进行 dropout 处理, 建立具有时间序列记忆功能的山区流域 LSTM 神经网络模型。运用该模型对余下的 9 场洪水进行测试, 并与 LMBP 模型进行对比。结果表明: LSTM 模型预测精度较高, 在洪水过程、洪峰流量和洪峰出现时间预测方面精度高于 LMBP 模型, 适用于山区流域洪水预报。

关键词: 洪水预报; LSTM 网络; LMBP 网络; 崇阳溪流域

中图分类号: TV124

文献标志码: A

文章编号: 1673-9868(2025)05-0177-11

开放科学(资源服务)标识码(OSID):



Research on Flood Forecasting Model for Mountainous Basin Based on LSTM

JIN Baoming¹, ZENG Hongyuan¹, LU Wangming²,
CHEN Chaoqing¹, KANG Shun¹

1. College of Civil Engineering, Fuzhou University, Fuzhou 350108, China;

2. Nanping Flood and Drought Disaster Prevention Center, Nanping Fujian 354200, China

Abstract: The flood in mountainous basin has the characteristics of strong suddenness and short forecast period. Rapid and accurate flood forecasting is always the key issue in the work of flood control. Based on the long-term and short-term memory deep learning neural network technology, this paper selects 30 rain-

收稿日期: 2024-11-03

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)。

作者简介: 金保明, 高级工程师, 博士, 主要从事水文水资源研究。

storm and flood processes in Chongyang River Basin from 1997 to 2022, including 21 floods as the training set, takes the hourly rainfall of six rainfall stations in the upper reaches such as Wubian and the previous flow of control section of Wuyishan station as the model input, and the corresponding flood flow of this section as the model output, and uses the root mean square error minimum criterion to analyze and determine the number of LSTM hidden layer units and network iteration rounds. At the same time, a full connection layer is set behind the LSTM layer, and the full connection layer is dropout processed to establish the LSTM neural network model with time series memory function for mountain basin. The model was used to test the remaining 9 floods and compared with the LMBP model. The results show that the LSTM model has higher prediction accuracy than the LMBP model in terms of flood process, peak discharge and peak time. It is suitable for flood prediction in mountainous basins.

Key words: flood forecast; LSTM network; LMBP network; Chongyang River basin

山区流域暴雨极易造成洪水灾害,因此洪水预报工作至关重要。除了采用传统的预报方法外,也可采用深度学习循环神经网络(Recurrent Neural Networks, RNN)洪水预报模型进行预报,长短时记忆神经网络(Long Short Term Memory, LSTM)模型就是其中的一种。文献[1]在一般 RNN 理论的基础上,提出了 LSTM 网络。近年来有不少学者开始把 LSTM 网络应用于水文序列的预测^[2]。文献[3]将 LSTM 和 BP 两种模型相结合进行降雨径流预测,预报精度符合要求。文献[4]比较了长短期记忆网络、一般循环网络、回声状态网络以及 GR4J 模型的日径流模拟效果,结果表明 LSTM 模型在中小流域降雨径流预报中效果更好。文献[5]对比了 LSTM 与萨克拉门托模型的径流预测结果,相对来说前者模拟效果更好。文献[6]采用 LSTM 网络研究受上游水库泄洪影响的 Mekong 河径流预测工作,预测结果良好。文献[7]建立了 LSTM 洪水预报模型,其表现出的效果比新安江模型好。文献[8]构建了三峡水库 LSTM 洪水预报模型,其效果优于 BPNN 和动态神经网络模型。文献[9]构建了 MPGA-LSTM 径流预测模型,对石砬站 2013—2017 年逐月径流过程进行预测,精度达到甲级标准。文献[10]利用渡里站逐时降雨和流量数据构建 BP 和 LSTM 网络进行流量预报,结果表明后者整体预报效果优于前者。文献[11]构建了考虑时空分布变化的 SLA-LSTM 模型,效果优于卷积网络模型。文献[12]将经验模态分解方法和 LSTM 网络相结合,使模型的模拟效果显著提升。文献[13]利用径向基函数(RBF)网络和降雨方差对洪水进行分级,建立 LSTM 洪水预报误差校正模型,对分级洪水预报结果进行校正,效果较好。文献[14]针对不同预见期建立白盆珠流域 LSTM 模型,并与新安江模型进行对比,证明了 LSTM 网络具有较高的预报精度。文献[15]引入 LSTM 网络建立大汶河流域洪水预报模型,预测结果较好。文献[16]建立 AR 和 LSTM 误差校正模型,对预报流量进行误差校正,结果表明 LSTM 模型效果优于 AR 模型,可有效提高洪水预报精度。文献[17]构建了基于 LSTM 的区域化洪水预报模型,模型能够较好地模拟实际洪水过程。文献[18]引入 LSTM 网络建立山区中小流域降雨径流模型,结果表明 LSTM 网络对山区中小流域暴雨洪水非线性关系具有良好的拟合效果。总体而言,LSTM 网络或耦合 LSTM 的相关模型在降雨径流和洪水预报方面表现突出,但该类模型在山区中小河流源头流域的洪水预报应用研究相对不多。为此本文构建崇阳溪上游流域 LSTM 洪水预报模型,为防洪工作服务。

1 LSTM 基本结构

LSTM 单元结构如图 1 所示, x_t 为输入, LSTM 单元包括遗忘门、输入门和输出门。

遗忘门为:

$$f_t = \sigma(\mathbf{W}_{xf}x_t + \mathbf{W}_{hf}h_{t-1} + \mathbf{b}_f) \quad (1)$$

式中: f_t 为 t 时刻遗忘门输出向量; $\sigma(\cdot)$ 为 sigmoid 激活函数; h_{t-1} 为 $t-1$ 时刻的隐藏状态; W_{xf} 、 W_{hf} 为 x_t 和 h_{t-1} 对应的遗忘门权值矩阵; b_f 为遗忘门的偏置矩阵。

输入门为:

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) \quad (2)$$

$$g_t = \tanh(W_{xg}x_t + W_{hg}h_{t-1} + b_g) \quad (3)$$

其中: i_t 为 t 时刻输入门输出向量; $\tanh(\cdot)$ 为双曲正切激活函数; W_{xi} 、 W_{hi} 为 x_t 和 h_{t-1} 对应的输入门权值矩阵; b_i 为输入门的偏置矩阵; g_t 为 t 时刻的单元状态候选向量; W_{xg} 、 W_{hg} 为 x_t 和 h_{t-1} 对应的 \tanh 层权值矩阵; b_g 为 \tanh 层的偏置矩阵。

单元状态

$$c_t = c_{t-1} \times f_t + g_t \times i_t \quad (4)$$

式中: c_t 、 c_{t-1} 分别为 t 、 $t-1$ 时刻的单元状态更新向量。

输出门为:

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) \quad (5)$$

$$h_t = o_t \times \tanh(c_t) \quad (6)$$

其中: o_t 为 t 时刻输出门输出向量; W_{xo} 、 W_{ho} 为 x_t 和 h_{t-1} 对应的输出门权值矩阵; b_o 为输出门的偏置矩阵; h_t 为 t 时刻的隐藏状态。

2 山区流域 LSTM 洪水预报模型构建

2.1 流域概况

选取崇阳溪上游流域为研究区域(图 2)。该流域位于福建省武夷山市,属于建溪支流崇阳溪的源头。武夷山水文站控制流域面积为 $1\,078\text{ km}^2$,包括东溪和西溪两条支流,流经地形多为山地丘陵,地势坡降大,属于典型的山区流域。雨季期间,暴雨频发容易导致洪水灾害。

2.2 样本数据处理

收集了该流域 1997 年至 2022 年间 30 场暴雨洪水,对其

发生过程进行分析并建模,其中训练集包括 21 场洪水、测试集包括 9 场洪水。在划分训练样本和测试样本的过程中,均综合考虑了高、中、低不同量级的洪水过程以及不同峰型(如单峰、双峰)的洪水,且样本数据具有代表性、可靠性、一致性、普遍适用性。测试集的 9 场洪水基本情况见表 1。


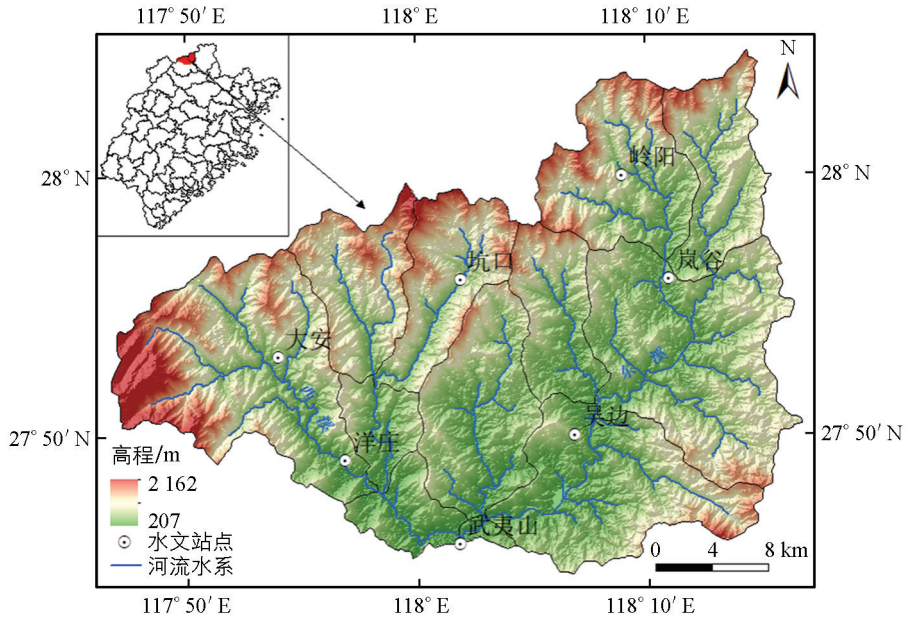


图 1 LSTM 单元结构图



该图基于自然资源部标准地图服务网站下载的审图号为 GS(2024)0650 号的标准地图制作,底图边界无修改。

图 2 流域水系图

表 1 测试集 9 场洪水基本情况表

洪水场次	洪峰流量/ ($\text{m}^3 \cdot \text{s}^{-1}$)	峰型	量级	洪水场次	洪峰流量/ ($\text{m}^3 \cdot \text{s}^{-1}$)	峰型	量级
19980614	2 960	双峰	高流量	20190705	1 790	双峰	中流量
20030625	791	单峰	低流量	20190709	2 763	单峰	高流量
20060614	737	单峰	低流量	20210628	1 698	双峰	中流量
20080719	2 172	单峰	高流量	20210630	1 237	双峰	中流量
20090420	685	单峰	低流量				

2.2.1 同步化处理

根据 LSTM 网络对时间序列的记忆能力,在模型数据输入之前需要将不同序列数据在时间尺度下进行统一,采用式(7)计算:

$$\mathbf{X}_i(t) = \mathbf{P}_i(t - \tau_i) \quad (7)$$

式中: $\mathbf{X}_i(t)$ 为 t 时刻第 i 个雨量站降雨过程 \mathbf{P}_i 对应的模型输入数据; τ_i 为其净雨到武夷山站的汇流时间。综合分析确定洋庄、吴边、大安、坑口、岭阳、岚谷各雨量站净雨到武夷山站的汇流时间分别为 1h、1.5 h、2.5 h、3 h、4 h、3 h。调整后的数据序列统一到同一个时间尺度下,以满足 LSTM 模型的输入要求。

2.2.2 标准化处理

模型输入数据包括流量和雨量两种类型,其来源和量纲不同,数据值域相差较大。为了适应 LSTM 网络的学习,论文采用(8)式所示 Z-score 标准化算法对数据进行标准化处理。

$$z = \frac{x - \mu}{\sigma} \quad (8)$$

式中: z 为标准化处理后的数据; x 为标准化处理前的数据; μ 为均值; σ 为标准差。经过处理后数据的均值为 0,标准差为 1,值域为 $[-1, 1]$,以此构建向量输入 LSTM 网络模型。在 LSTM 网络模型训练结束后,对输出的预测结果再经过反标准化处理得到实际的输出预测值。

2.2.3 子流域单元划分

为衡量各雨量站的雨量在产汇流过程中的占比,需要对该流域进行单元划分,计算各控制站点子流域单元面积权重。根据泰森多边形法将流域划分为 7 个子单元,各单元面积和权重占比见表 2。

表 2 崇阳溪上游各子流域单元面积权重表

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

2.3 模型构建

以崇阳溪上游 6 个雨量站的时段雨量数据为基础、增加流域控制断面武夷山水文站前 1 h 的流量数据作为模型输入,以该站对应流量数据为预测目标,建立山区流域 LSTM 神经网络洪水预报模型。网络模型结构如图 3 所示。

输入层计算式为:

$$\begin{cases} \mathbf{X}_j(t) = \{a \log_{10}[\lambda_j \mathbf{P}_j(t - \tau_j) + b] - \mu_{pj}\} / \sigma_{pj}, j = 1, 2, \dots, 6 \\ \mathbf{X}_7(t) = [\mathbf{Q}(t - 1) - \mu_q] / \sigma_q \\ \mathbf{X}(t) = [\mathbf{X}_1(t), \mathbf{X}_2(t), \dots, \mathbf{X}_7(t)]^T \end{cases} \quad (9)$$

式中: a 、 b 为去零化参数,取 $a = 0.5$ 、 $b = 2$; λ_j 为各雨量站子流域单元面积权重; μ_{pj} 、 σ_{pj} 分别为输入的各雨量站时段雨量序列均值、标准差; μ_q 、 σ_q 分别为武夷山水文站实测流量序列均值、标准差。 t 时刻模型输入层的输入包括:同步后的 6 个雨量站时段雨量 $\mathbf{P}_j(t - \tau_j)$;前 1 h 武夷山水文站记录的实测流量 $\mathbf{Q}(t - 1)$,经该层预处理后转化为 LSTM 层的输入信息矩阵 $\mathbf{X}(t)$ 。

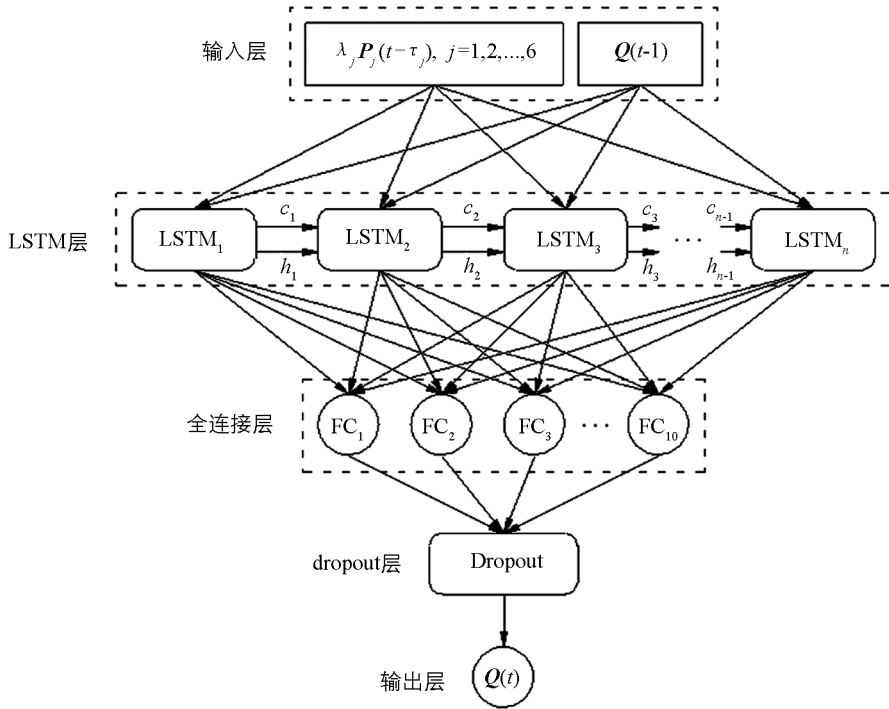


图 3 山区流域 LSTM 神经网络洪水预报模型结构

LSTM 层计算式为:

$$\begin{cases} \mathbf{i}(t) = \sigma[\mathbf{W}_{xi}\mathbf{X}(t) + \mathbf{W}_{hi}\mathbf{h}(t-1) + \mathbf{b}_i] \\ \mathbf{f}(t) = \sigma[\mathbf{W}_{xf}\mathbf{X}(t) + \mathbf{W}_{hf}\mathbf{h}(t-1) + \mathbf{b}_f] \\ \mathbf{g}(t) = \tanh[\mathbf{W}_{xg}\mathbf{X}(t) + \mathbf{W}_{hg}\mathbf{h}(t-1) + \mathbf{b}_g] \\ \mathbf{o}(t) = \sigma[\mathbf{W}_{xo}\mathbf{X}(t) + \mathbf{W}_{ho}\mathbf{h}(t-1) + \mathbf{b}_o] \\ \mathbf{c}(t) = \mathbf{c}(t-1) \times \mathbf{f}(t) + \mathbf{g}(t) \times \mathbf{i}(t) \\ \mathbf{h}(t) = \mathbf{o}(t) \times \tanh \mathbf{c}(t) \end{cases} \quad (10)$$

t 时刻 LSTM 层的输入包括: $t-1$ 时刻记忆单元输出的武夷山站流量信息矩阵 $\mathbf{h}(t-1)$; $t-1$ 时刻记忆单元根据输入信息学习到的状态变量矩阵 $\mathbf{c}(t-1)$; 当前输入信息矩阵 $\mathbf{X}(t)$ 。经过输入门、遗忘门、输出门的激活函数运算, 舍弃使损失函数增大的负面信息, 记录对预测精度有正反馈的信息并更新单元状态, 以此生成当前流域出口断面流量信息矩阵 $\mathbf{h}(t)$ 。

在 LSTM 层之后设置了一个包含 10 个单元的全连接层, 用于将 LSTM 层各单元训练学习得到的数据特征进行整合, 以达到最终需要输出维度为 1 的结果。全连接层计算式为:

$$y_i(t) = \sigma\left(\sum_{k=t-n}^n \mathbf{W}_{yk}\mathbf{h}(k) + \mathbf{b}_{yk}\right) \quad (11)$$

式中: $y_i(t)$ 为全连接层各单元输出信息, 由 LSTM 层各单元输出的武夷山站流量信息矩阵 $\mathbf{h}(k)$ 整合而来; n 为 LSTM 层单元数; \mathbf{W}_{yk} 、 \mathbf{b}_{yk} 为全连接层的权值矩阵和偏置值。

在网络隐含层和输出层之间的全连接层进行 dropout 处理, 抛弃因子设置为 10%, 该设置会在训练期间将全连接层 10% 的随机单元输出设置为零, 以便网络进行更稳健的特征学习, 从而增强模型的泛化能力并降低网络过拟合风险。dropout 层计算式为:

$$\mathbf{Y}(t) = \text{dropout}\left[\sum_{i=1}^{10} \mathbf{y}_i(t)\right] \quad (12)$$

式中: $\mathbf{Y}(t)$ 为 dropout 层输出信息, 由全连接层各单元输出信息整合而来, dropout 层使用了由 0 和 1 组成的 10×1 随机数矩阵以抛弃冗余信息。

在 t 时刻, 经全连接层整合、dropout 层随机数筛选后再由输出层去标准化, 最终获得预测流量值。输出层计算式为:

$$Q(t) = \sigma_q Y(t) + \mu_q \quad (13)$$

式中: $Q(t)$ 为武夷山站预测流量值; μ_q 、 σ_q 含义同式(9)。

2.4 模型参数率定

通过分析训练集洪水流量均方根误差(RMSE)平均值随 LSTM 层隐含层单元数和网络迭代轮数组合变化而变化的情况, 以此判定两个参数的最优组合。模型学习速度取 0.01。表 3 为模型训练结束后, 训练集洪水的 RMSE 平均值随 LSTM 层隐含层单元数(hidden units)和网络迭代轮数(epochs)组合变化的趋势, 并绘制其三维曲面、二维等值线图, 详见图 4 所示。

表 3 不同隐含层单元数和网络迭代轮数组合下训练集 RMSE 均值统计表

$m^3 \cdot s^{-1}$

网络迭代轮数	隐含层单元数					
	8	16	32	64	128	256
50	119.5	110.7	100.0	98.0	100.8	101.1
100	97.2	94.0	90.5	93.4	100.8	98.4
150	97.3	94.5	95.5	99.8	106.7	101.3
200	97.4	95.7	101.0	106.3	108.3	102.1
250	98.6	98.8	100.9	106.2	107.4	102.7
300	99.1	102.0	110.6	111.7	108.0	103.9

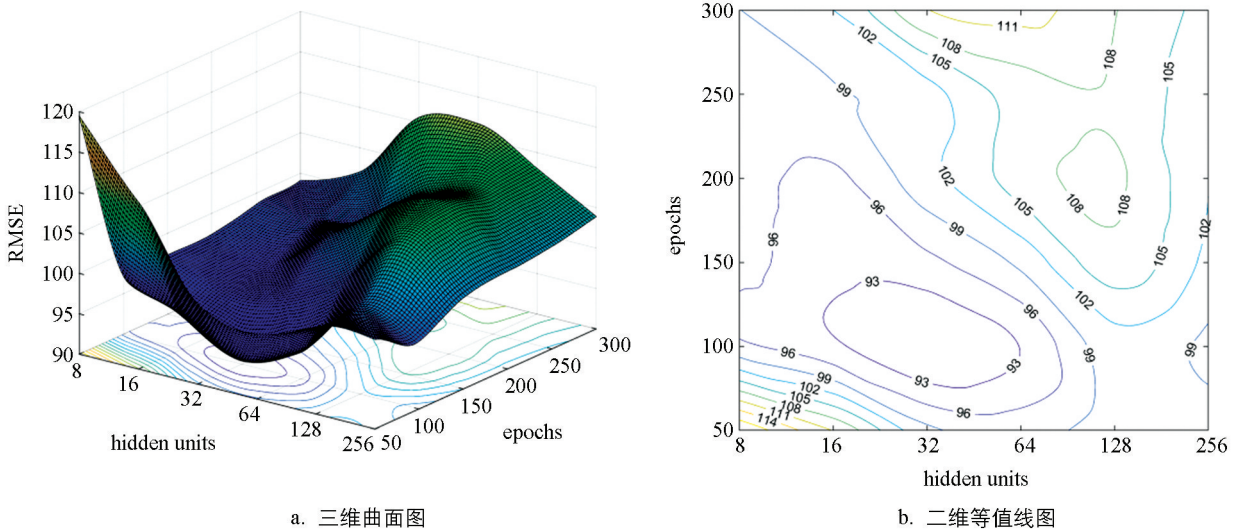


图 4 RMSE 随隐含层单元数和网络迭代轮数变化示意图

根据表 2 和图 4 可见, 当 LSTM 层隐含层单元数为 8、网络迭代轮数为 50 次时, RMSE 值较大, 网络由于参数迭代不足而未收敛; 随着两个参数的增加, RMSE 值逐步降低, 当隐含层单元数为 32、迭代轮数为 100 次时, RMSE 达到最小; 随着两个参数继续增大, RMSE 值又开始上升。整体趋势面图像呈现出两端高、中间低的“山谷”形态。故最终确定 LSTM 隐含层单元数为 32、网络迭代轮数为 100。

根据选定的 LSTM 隐含层单元数和网络迭代轮数设置模型结构。在多次试算并反复调整参数后, 损失函数变化曲线趋于平稳, 网络训练结束, 至此完成 LSTM 神经网络洪水预报模型的构建。

2.5 模型验证

采用上述模型对选定的测试集 9 场暴雨洪水过程进行模拟验证, 得到 9 场洪水流量预报过程线图(图 5)。为了进行对比, 同样采用训练集样本构建流域 LMBP 神经网络洪水预报模型, 调试后的模型结构为 7-8-1, 即输入层单元数为 7、隐含层单元数为 8、输出层单元数为 1, 对选定的测试集 9 场暴雨洪水过程进行模拟, 结果见图 6。

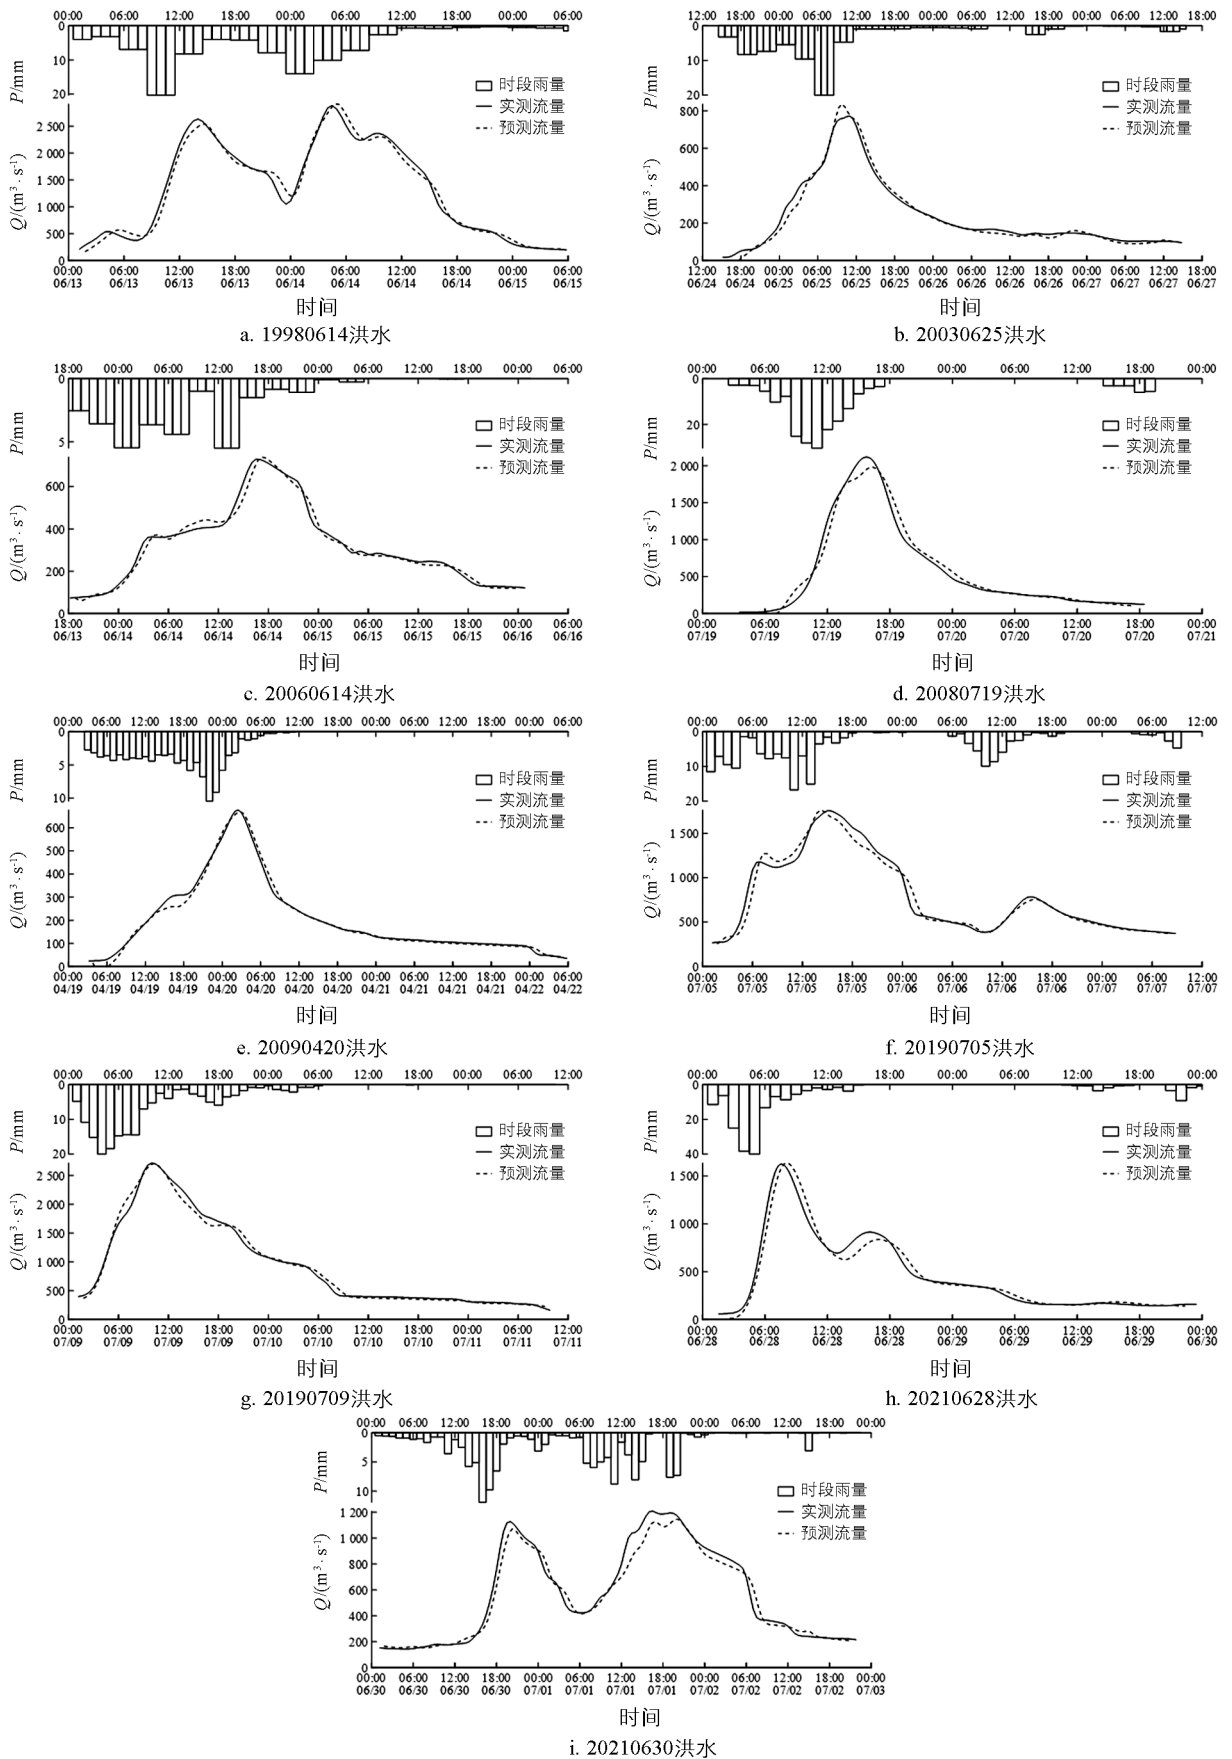


图 5 崇阳溪上游流域 9 场洪水 LSTM 模型预报过程线

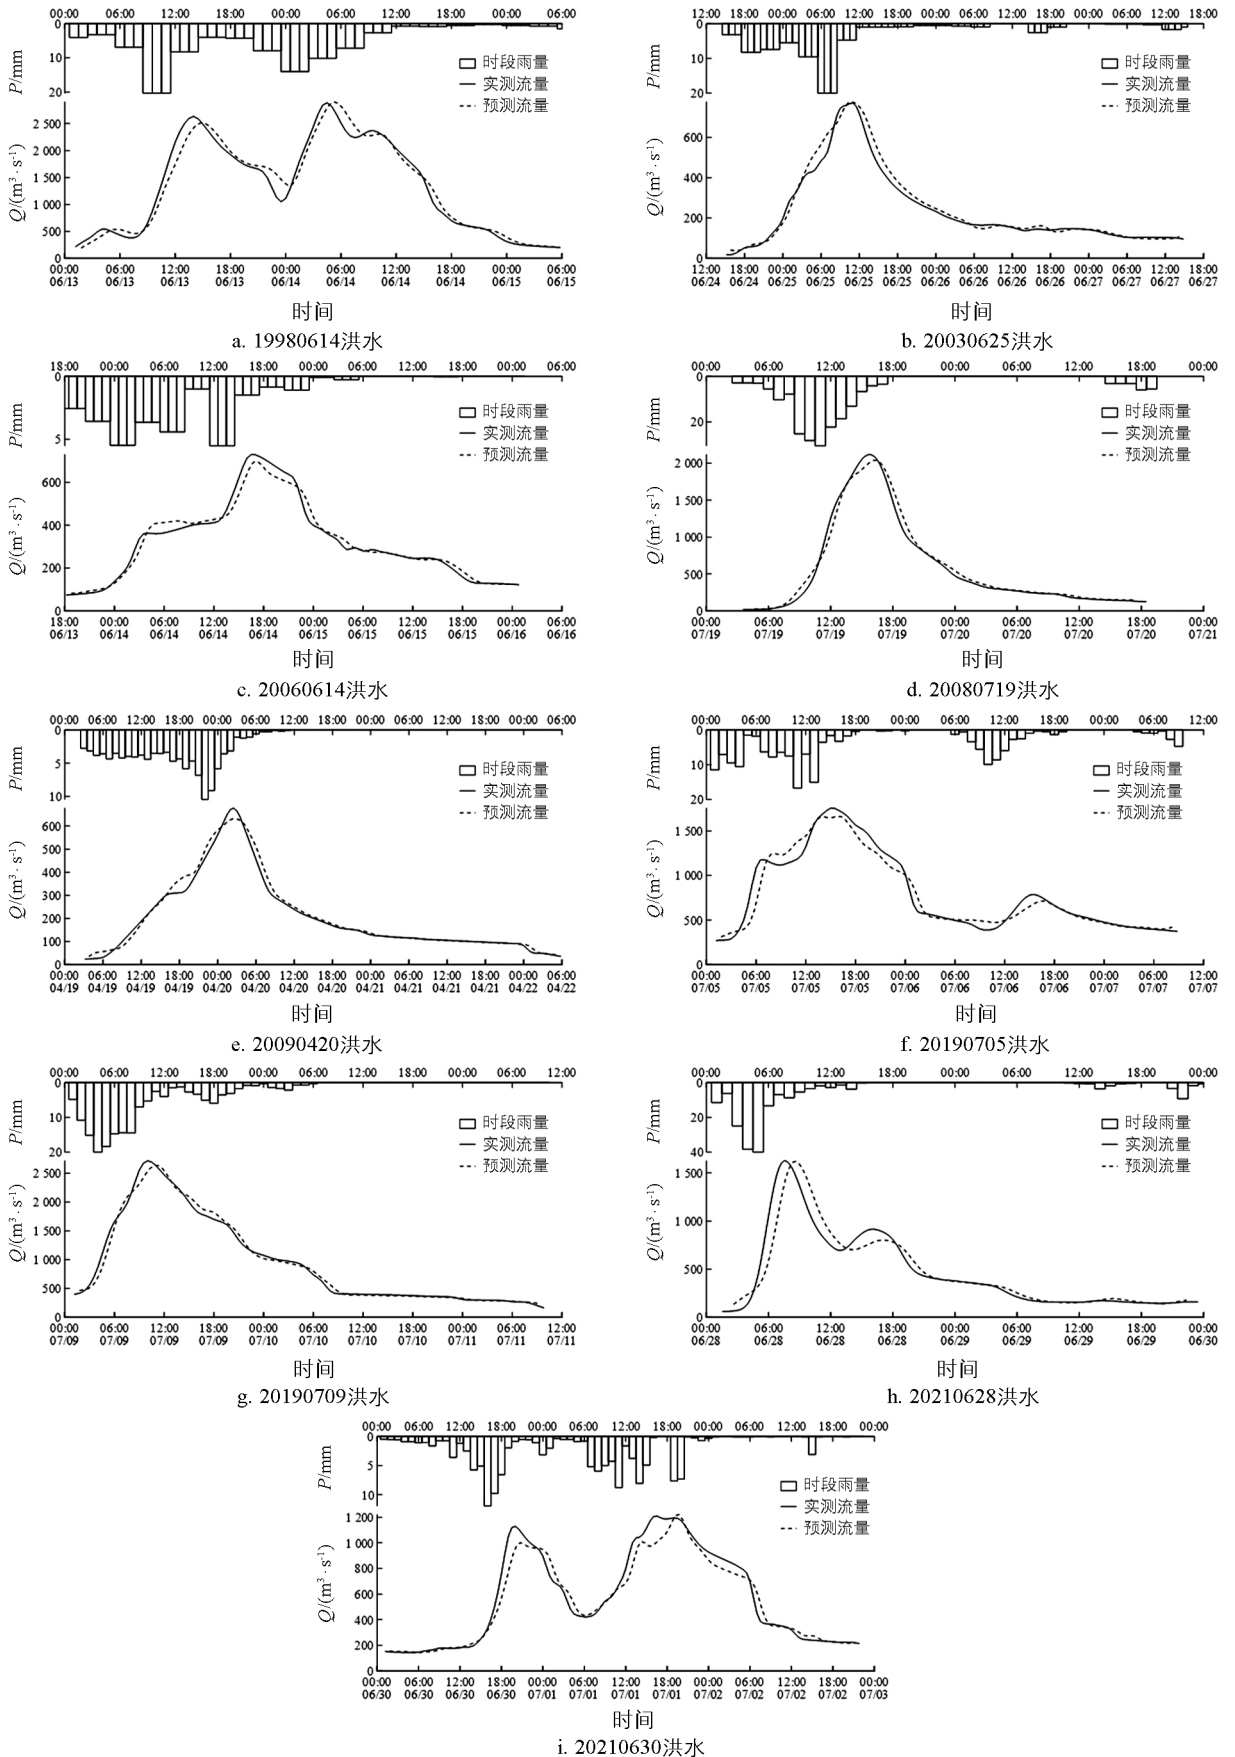


图 6 崇阳溪上游流域 9 场洪水 LMBP 模型预报过程线

采用绝对误差绝对值的平均值(取完绝对值后再平均, 下同)、相对误差绝对值的平均值、纳什效率系数 3 个评定指标对两个模型精度进行综合分析, 得到每场洪水流量过程预报误差见表 4, 洪峰流量相对误差和洪峰出现时间误差见表 5。其中相差时间是指洪峰出现预测时间减去实际出现时间。

表 4 9 场洪水过程预报误差分析表

洪水场次	LSTM 模型					LMBP 模型				
	绝对误差/($\text{m}^3 \cdot \text{s}^{-1}$)		相对误差/%		纳什效率系数	绝对误差/($\text{m}^3 \cdot \text{s}^{-1}$)		相对误差/%		纳什效率系数
	最大值	平均值	最大值	平均值		最大值	平均值	最大值	平均值	
19980614	230	37.2	15.2	6.3	0.960	286	68.0	-54.9	11.6	0.951
20030625	116	12.0	-36.8	9.5	0.961	75	11.5	39.7	10.3	0.963
20060614	76	12.6	-20.2	4.7	0.962	-73	13.6	34.2	8.3	0.951
20080719	-113	37.2	31.4	10.4	0.952	-116	28.1	43.7	6.9	0.968
20090420	-57	12.5	-19.2	5.2	0.985	41	13.9	47.3	8.1	0.980
20190705	215	34.0	-18.7	8.8	0.924	197	39.4	-55.4	15.7	0.910
20190709	175	27.7	11.1	3.6	0.987	-110	33.1	39.3	3.8	0.980
20210628	-173	30.1	18.5	7.1	0.926	-192	40.1	-55.6	16.8	0.852
20210630	-161	53.7	-25.6	4.9	0.938	-153	59.9	54.2	10.5	0.924

表 5 9 场洪水洪峰流量和洪峰出现时间预报误差分析表

洪水场次	峰型	实测值		LSTM 模型					LMBP 模型			
		洪峰流量/ ($\text{m}^3 \cdot \text{s}^{-1}$)	洪峰出 现时间	洪峰流量/($\text{m}^3 \cdot \text{s}^{-1}$)			预测洪 峰时间	相差 时间	洪峰流量/($\text{m}^3 \cdot \text{s}^{-1}$)		预测洪 峰时间	相差 时间
				预测	绝对 误差	相对 误差/%			预测	相对 误差/%		
19980614	主峰	3 080	4: 24	3 255	175	5.7	5: 00	0: 36	3 030	-1.6	5: 00	0: 36
	次峰	2 710	14: 00	2 606	-104	-3.9	14: 00	0: 00	2 593	-4.3	15: 00	1: 00
20030625	主峰	797	9: 24	852	55	6.9	9: 00	-0: 24	793	-0.4	9: 00	-0: 24
20060614	主峰	737	16: 00	782	45	6.0	16: 00	0: 00	752	2.1	16: 00	0: 00
20080719	主峰	2 172	16: 00	2 148	-24	-1.1	17: 00	1: 00	2 134	-1.8	17: 00	1: 00
20090420	主峰	685	2: 00	692	7	1.1	2: 00	0: 00	644	-5.9	2: 00	0: 00
20190705	主峰	1 830	15: 20	1940	110	6.0	15: 00	-0: 20	1 738	-5.0	14: 00	-1: 20
	次峰	798	15: 00	800	2	0.3	15: 00	0: 00	741	-7.2	16: 00	1: 00
20190709	主峰	2 770	10: 20	2 798	28	1.0	10: 00	-0: 20	2 684	-3.1	11: 00	0: 40
20210628	主峰	1 700	7: 15	1 811	111	6.5	8: 00	0: 45	1 794	5.6	8: 00	0: 45
	次峰	938	15: 00	891	-47	-5.0	16: 00	1: 00	826	-11.9	16: 00	1: 00
20210630	主峰	1 237	20: 40	1 212	-25	-2.0	21: 00	0: 20	1 272	2.8	22: 00	1: 20
	次峰	1 150	16: 45	1 121	-29	-2.5	17: 00	0: 15	1 032	-10.3	17: 00	0: 15
平均值	-	-	-	-	58.6	3.7	-	0: 23	-	4.8	-	0: 43

综合 LSTM 模型整个预报过程线来看,除 20080719 洪水过程平均相对误差为 10.4%外,其他误差均小于 10%,模型确定性系数均大于 0.920。与 LMBP 模型的结果比较,9 场洪水流量预报过程中,有 8 场洪水相对误差的平均值小于 LMBP 模型的误差,7 场洪水的确定性系数大于后者的确定性系数。

洪峰流量方面,9 场洪水的洪峰流量绝对误差总体较小,平均值为 $58.6 \text{ m}^3/\text{s}$,误差最大值出现在 19980614 洪水主峰,误差为 $175 \text{ m}^3/\text{s}$,高流量洪水的绝对误差大于中低流量洪水。9 场洪水的洪峰流量相对误差都处在较为理想的范围,平均值仅为 3.7%,误差最大值出现在 20030625 洪水主峰,误差 6.9%。LSTM 模型在洪峰流量预测方面也相对占优,误差较小,精度略高于 LMBP 模型。

洪峰出现时间方面,9 场洪水洪峰出现时间误差最大值为 1 h,最小值为 0,平均时间误差为 23 min,处于允许的时差范围。每场洪水预测洪峰出现时间相较实测值或早或晚,但总体上偏晚居多。与 LMBP 模型相比,LSTM 模型在洪峰出现时间预测方面性能更好,精度更高。

总体而言,两种模型的精度均符合规范要求,相对来说深度学习 LSTM 模型具有显著优势。

3 结语

针对崇阳溪源头山区流域地形地貌复杂的特点,选取流域暴雨洪水过程,采用均方根误差最小准则优化率定网络的 LSTM 隐含层单元数和网络迭代轮数,在 LSTM 层之后设置了一个包含 10 个单元的全连接层,并对全连接层进行 dropout 处理,建立崇阳溪上游山区流域 LSTM 神经网络洪水预报模型。该网络适合于模拟序列中具有时间间隔和延迟的数据关系,以此生成流域出口断面流量过程信息。同时构建了该流域的 LMBP 模型进行比较,主要结论如下:

1) LSTM 与 LMBP 模型的对比结果表明,具有深度学习功能的 LSTM 模型预测精度较高,其在洪水过程、洪峰流量和洪峰出现时间预测方面的精度高于人工神经网络 LMBP 模型,模型的确定性系数也明显占有优势,因此适用于山区源头流域的洪水预报。

2) 通过考虑雨量站净雨到控制断面的汇流时间,将不同序列数据在时间尺度下进行同步化处理后作为模型的输入,预报效果相对更好。

3) 在 LSTM 层之后设置全连接层并对全连接层进行 dropout 处理,其在 LSTM 层隐含层单元数和网络迭代轮数的优化组合选择中具有较好的优势,可以提高模型的泛化能力。

参考文献:

- [1] HOCHREITER S, SCHMIDHUBER J. Long Short-Term Memory [J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [2] 吴剑. 基于长短时记忆网络的山丘区中小河流洪水预报研究 [D]. 大连: 大连理工大学, 2021.
- [3] 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, 92.
- [4] TIAN Y, XU Y P, YANG Z L, et al. Integration of a Parsimonious Hydrological Model with Recurrent Neural Networks for Improved Streamflow Forecasting [J]. *Water*, 2018, 10(11): 1655.
- [5] 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.

- [6] LE X H, HO H V, LEE G, et al. Application of Long Short-Term Memory (LSTM) Neural Network for Flood Forecasting [J]. *Water*, 2019, 11(7): 1387.
- [7] 殷兆凯, 廖卫红, 王若佳, 等. 基于长短时记忆神经网络(LSTM)的降雨径流模拟及预报 [J]. *南水北调与水利科技*, 2019, 17(6): 1-9, 27.
- [8] ZHOU Y, GUO S, CHANG F, et al. Hydrological Forecasting Using Artificial Intelligence Techniques [J]. *Journal of Water Resources Research*, 2019, 8(1): 1-12.
- [9] 张森, 颜志俊, 徐春晓, 等. 基于 MPGA-LSTM 月径流预测模型及应用 [J]. *水电能源科学*, 2020, 38(5): 38-41, 75.
- [10] 崔巍, 顾冉浩, 陈奔月, 等. BP 与 LSTM 神经网络在福建小流域水文预报中的应用对比 [J]. *人民珠江*, 2020, 41(2): 74-84.
- [11] DING Y K, ZHU Y L, FENG J, et al. Interpretable Spatio-Temporal Attention LSTM Model for Flood Forecasting [J]. *Neurocomputing*, 2020, 403: 348-359.
- [12] 刘扬, 王立虎. 基于改进 EMD-LSTM 的洪水预测方法研究 [J]. *水利水电技术(中英文)*, 2022, 53(1): 35-44.
- [13] 李志超, 张怡雯, 邬强, 等. 基于分级优化与 LSTM 方法的中小流域洪水预报研究 [J]. *水利水电技术(中英文)*, 2022, 53(8): 41-49.
- [14] 罗朝林, 张波, 孟庆魁, 等. 基于长短时记忆神经网络的水库洪水预报 [J]. *人民珠江*, 2022, 43(12): 128-134.
- [15] 王逸阳. LSTM 与多头注意力机制视角下的洪水预报模型研究 [D]. 郑州: 华北水利水电大学, 2023.
- [16] 李志超, 邬强, 胡彩虹, 等. 基于 LSTM 误差校正蓄满-超渗兼容模型的山洪预报研究 [J]. *武汉大学学报(工学版)*, 2023, 56(10): 1161-1171.
- [17] 毕成琳, 刘匡, 向征, 等. 洪水预报区域化 LSTM 模型研究 [J]. *水电能源科学*, 2023, 41(12): 63-67.
- [18] 张锦堂, 任明磊, 李京兵, 等. 基于长短时记忆网络的山区中小流域降雨径流模拟 [J]. *水电能源科学*, 2024, 42(8): 33-37.

责任编辑 张构