

基于循环神经网络的洞庭湖水位预测研究

郭燕^{1, 2} 赖锡军¹¹

(1. 中国科学院南京地理与湖泊研究所/

中国科学院流域地理学重点实验室, 江苏 南京 210008;

2. 中国科学院大学 资源与环境学院, 北京 100049)

【摘要】: 洞庭湖流域分布了3个重要的自然保护区, 是我国大型淡水湖泊湿地系统之一, 生态资源丰富。水位是维持其生态系统结构、功能和完整性的基础。为预测长江和流域“四水”来水组合影响下的洞庭湖水位变化, 该文采用两种循环神经网络方法——长短期记忆(LSTM)和门控循环单元(GRU), 构建了洞庭湖水位变化的预测模型。LSTM和GRU的优势在于能够学习网络的输入和输出之间的长期依赖关系, 这对于模拟受上游来水影响的水位累积变化至关重要。模型以湘江、资水、沅江、澧水入湖流量和长江干流宜昌站前期流量作为输入条件, 预测洞庭湖不同湖区的水位变化过程。利用1980~2002年水位流量时间序列数据对模型进行测试, 2003~2014年数据进行验证, 并对两种模型的预测结果进行了比较。结果表明: (1)循环神经网络LSTM和GRU方法均可合理预测洞庭湖水位的变化过程, NSE和 R^2 均为0.91~0.95, 各站水位预测的RMSE值为0.41~0.86m, NSE和 R^2 均为0.91~0.95; (2)LSTM的预测精度稍高于GRU, 但GRU计算更高效, 是LSTM一个很好的替代方案; (3)模型能够较准确的模拟一次洪水事件, 洪水位的预测值与真实值的最大相对误差低于5%;且模型具有较好的多步长时间序列预测能力, 有在水文模型应用方面的潜力。

【关键词】: 水位预测 江湖作用 洞庭湖

【中图分类号】: P343.3 **【文献标识码】:** A **【文章编号】:** 1004-8227(2021)03-0689-10

洞庭湖是长江中游重要的通江湖泊和水源地, 具有重要的调洪防汛功能。近年来, 受气候变化和三峡大坝等的影响, 洞庭湖秋季枯水期明显提前, 枯水位持续时间显著增长^[1,2]。在水文情势变化的驱动下, 洞庭湖湖泊湿地的泥沙淤积过程和湿地景观格局发生明显变化^[3,4], 湖泊生态系统面临生物多样性减少^[5,6]和生态服务功能下降^[7]等问题。由于江湖水系统交互作用的复杂性, 构建一个可靠的系统水量模型是当前洞庭湖水量平衡研究的重点。为了研究该大型水系统, 常用水文学和水动力学方法^[8~11]。水文水动力模型对建模技术能力和基础资料要求较高, 而且对洞庭湖这样大型水系统的模拟, 计算代价高、效率相对较低, 高效预测水位仍存挑战^[12,13]。

1990s以来, 人工智能方法因擅长解决受多种复杂因素影响的非线性模拟和预测问题, 而受到众多学科领域的广泛关注。其中, 人工神经网络(ANN)作为一种基于数据驱动的、具有任意函数映射能力的自适应性方法, 在水文学研究中发展迅速^[14~16]。随

作者简介: 郭燕(1996~), 女, 硕士研究生, 主要研究方向为水文与水资源. E-mail: guoyan17@mails.ucas.ac.cn

赖锡军, E-mail: xjlai@niglas.ac.cn

基金项目: 中国科学院战略性先导科技专项(A类)(XDA230402)

着计算机技术的发展, Lecun 等发现 ANN 存在难以解决时间序列出现的梯度消失或爆炸、特征提取能力有限等不足^[17,18], 深度学习学习方法随之应运而生。其中, 深度学习循环神经网络 LSTM、GRU 等, 解决了 ANN 输入与输出之间的长期依赖关系问题, 利用前期历史信息, 在水库流量、管道水量以及流域特征水文变量等预测的应用中得到了成功应用^[19~25]。洞庭湖水位受流域“四水”和长江来水多重控制, 其变化与二者之间存在复杂的非线性关系, 难以采用简单的统计模型模拟预测水位和来水的响应关系。LSTM 独特的“三门一状态”的门控结构, GRU 作为其升级变体, 能够包含流域内的储存效应信息, 这部分变量可能对水文过程发挥着重要作用^[26,27]。

本文选取洞庭湖为研究对象, 利用 LSTM 和 GRU 两种神经网络方法, 建立洞庭湖日尺度水位预测模型, 探讨其用于预测江湖交互作用下洞庭湖水位变化过程的潜力, 为洞庭湖水量平衡研究提供一个快速有效的预测方法。

1 资料与方法

1.1 研究区概况

洞庭湖位于长江中下游南岸, $110^{\circ} 40' E \sim 113^{\circ} 10' E, 28^{\circ} 30' N \sim 30^{\circ} 20' N$ 之间, 是我国第二大淡水湖泊, 也是长江中下游地区唯二的与长江保持着自然连通状态的吞吐型湖泊之一^[28]。全流域总体地势是西高东低, 湖泊入湖水量由三部分组成: 北边松滋、太平、藕池(称三口)分泄长江水量, 占 33.5%; 流域西南边湘江、资水、沅江、澧水(称“四水”)入湖水量, 占 57.8%; 以及区间新墙河、汨罗江等中小河流来水, 占 8.7%^[29]。来水通过西、南和东洞庭湖调蓄后经唯一出水口城陵矶入江。

1.2 数据

研究选用西洞庭湖南咀和小河咀站、南洞庭湖沅江和营田站、东洞庭湖鹿角和城陵矶站逐日平均水位数据, 以及长江干流宜昌站、湘江湘潭站、资水桃江站、沅江桃源站、澧水石门站逐日平均流量数据建模, 时间序列尺度为 1980~2014 年。

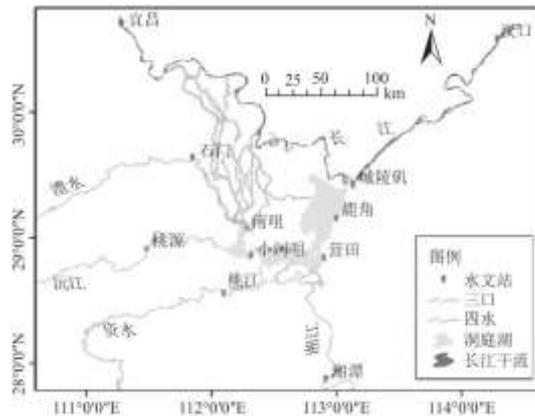


图 1 洞庭湖监测站点空间分布示意图

1.3 研究方法

通过在 Python3.6.5 中的 keras 深度学习库^[30]搭建用于多步多变量时间序列预测的 LSTM 和 GRU 神经网络水文预测模型。

1.3.1 LSTM

LSTM 是 1997 年 Hocheriter 和 Schmidhuber 为了解决 ANN 的梯度消失或爆炸缺陷而开发的、被 Gers 等进一步改进和发展的一种新的递归模型^[31, 32]。LSTM 内部主要由遗忘、输入、输出 3 个门控单元，其主要输入输出结构如图 2 所示，相比 ANN 只有一个传递状态 h ，LSTM 有两个传输状态 C_t 和 h_t 。其内部主要的计算过程如下：

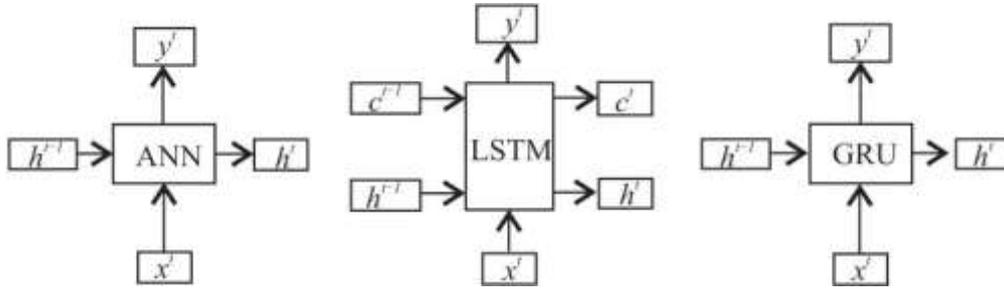


图 2 ANN、LSTM、GRU 的输入输出结构图

$$f_t = \sigma(W_{sf} X_t + W_{hf} h_{t-1} + b_f) \quad (1)$$

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

$$\hat{C}_t = \tanh(W_{sc} X_t + W_{hc} h_{t-1} + b_c) \quad (3)$$

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

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

$$h_t = o_t * \tanh(C_t) \quad (6)$$

式中： f_t, i_t, o_t, C_t, h_t 分别是遗忘门、输入门、输出门、记忆单元和隐藏输出状态； W 是相应的权重矩阵； b 是偏差矩阵； σ 和 \tanh 是激活函数。

1.3.2 GRU

GRU 是 Cho 等^[33]针对消失梯度问题而提出来的一种循环神经网络。GRU 的输入输出结构和 ANN 一样，但内部思想与 LSTM 非常相似，也使用门来调节隐藏层神经元内部的信息流。不同的是，GRU 只有重置门和更新门两个门控单元。其内部主要的计算过程如下：

$$z_t = \sigma(W_{xz} X_t + W_{hz} h_{t-1} + b_z) \quad (7)$$

$$r_t = \sigma(W_{xr} X_t + W_{hr} h_{t-1} + b_r) \quad (8)$$

$$\hat{U}_t = \tanh(W_{xh} X_t + r_t * W_{hh} h_{t-1} + b_h) \quad (9)$$

$$h_t = (1 - z_t) * \hat{U}_t + z_t * h_{t-1} \quad (10)$$

式中： z_t, r_t, \hat{U}_t 分别是更新门、重置门、记忆单元。

1.3.3 评价指标

采用均方根误差 (RMSE)、纳什效率系数 (NSE) 决定系数 (R^2) 3 个指标对模型模拟的效果进行评价。

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i^{obs} - Y_i^{pre})^2}{n}} \quad (11)$$

$$NSE = 1 - \left[\frac{\sum_{i=1}^n (Y_i^{obs} - Y_i^{pre})^2}{\sum_{i=1}^n (Y_i^{obs} - Y^{mean})^2} \right] \quad (12)$$

$$R^2 = \left[\frac{(\sum_{i=1}^n (Y_i^{pre} - Y^{mean})(Y_i^{obs} - Y^{mean}))^2}{\sum_{i=1}^n (Y_i^{pre} - Y^{mean})^2 \sum_{i=1}^n (Y_i^{obs} - Y^{mean})^2} \right] \quad (13)$$

式中： Y_i^{obs} 、 Y_i^{pre} 、 Y^{mean} 、 Y_{pre}^{mean} 分别表示观测值、预测值、观测值的平均值和预测值的平均值；n 为数据长度。

2 结果分析与讨论

2.1 模型参数

采用单层循环神经网络建模，利用 1980~2002 年实测数据建立模拟模型，2003~2014 年数据进行验证。以长江干流宜昌站和“四水”各站的日均流量为输入数据，模拟预测西、南、东洞庭湖区各代表站水位。其中，单层神经网络层设置 50 个神经元，选用基于梯度下降的 ADAM 自适应学习率优化算法作为优化器，初始学习率为 0.001，模型损失函数选用均方根误差，采用 Dropout 正则化方法防止模型过拟合。神经网络结构见图 3，表达式如下。

$$h_i^{t+1} = f(Q_j^t, Q_j^{t-1}, \dots, Q_j^{t-n+1}) \quad (14)$$

式中： h_i^{t+1} 为未来 1d 的水位； Q_{tjjt} 为当前时刻流量； Q^{t-n+1} 为输入时间窗为前 nd 时刻的流量。其中，i 取 1~6 分别表示南咀、小河咀、沅江、营田、鹿角和城陵矶站的日均水位，j 取 1~5 分别表示湘潭站、桃源站、桃江站、石门站和宜昌站的日均流量。

考虑到流量与水位之间的响应关系，分别试验了 5 种滞时方案下的输入：(1) 宜昌站前 5d、石门站前 3d、湘潭、桃江、桃源(后文称“其它三站”)前 2d 的流量；(2) 宜昌站前 5d、石门站前 2d、其它 3 站前 2d 的流量；(3) 宜昌站前 5d、石门站前 2d、其它三站前 1d 的流量；(4) 宜昌站前 3d、石门站前 2d、其它 3 站前 1d 的流量；(5) 宜昌站前 3d、石门站前 1d、其它 3 站前 1d 的流量。分别来预测洞庭湖不同湖区代表站(南咀、小河咀、沅江、营田、鹿角和城陵矶站)未来 1d 的日均水位。

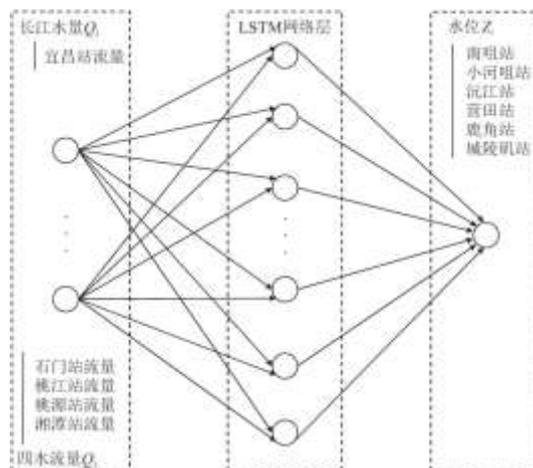


图3 单层神经网络模型结构图

2.2 LSTM 水位预测

LSTM 神经网络能够较为准确地模拟洞庭湖在长江来水和流域“四水”来水组合作用下的水位变化过程。通过比较五种滞时方案下的模拟结果，考虑来水传输距离和速率的影响，综合来说，方案④下，即利用宜昌站前 3d、石门前 2d、其它三站前 1d 流量作为输入，能更好地预测洞庭湖不同湖区代表站点未来 1d 的水位变化。其中，训练阶段各站水位预测的 RMSE 值为 0.41~0.86m、NSE 和 R^2 值为 0.91~0.95；验证阶段各站水位预测的 RMSE 值为 0.37~0.93m、NSE 为 0.90~0.94、 R^2 值为 0.92~0.95。

2.3 GRU 与 LSTM 预测对比分析

结合上游流量过程和洞庭湖水位变化响应的实际滞时以及多次模拟计算，我们认为利用长江干流前 3d，澧水前 2d 以及沅江、资水、湘江前 1d 的流量对洞庭湖不同湖区水位的模拟是最合理的。因此，我们比较了该滞时方案下 LSTM 和 GRU 两种神经网络对湖泊水位的模拟结果。

LSTM 和 GRU 两种方法都给出了较高精度洞庭湖水位预测结果(表 1)。训练阶段，LSTM 对不同代表站水位模拟的 RMSE 范围是 0.41~0.86m，NSE 和 R^2 均为 0.91~0.95；GRU 模拟的 RMSE 范围是 0.52~0.92m，NSE 为 0.86~0.94， R^2 为 0.89~0.94。验证阶段，LSTM 模拟的 RMSE 值是 0.37~0.93m，NSE 为 0.90~0.94， R^2 为 0.92~0.95；GRU 模拟的 RMSE 值为 0.40~0.99m，NSE 为 0.89~0.94， R^2 为 0.90~0.95。两者对比表明，在该预测方案中，LSTM 模型的精度要高于 GRU，表达性能更好。

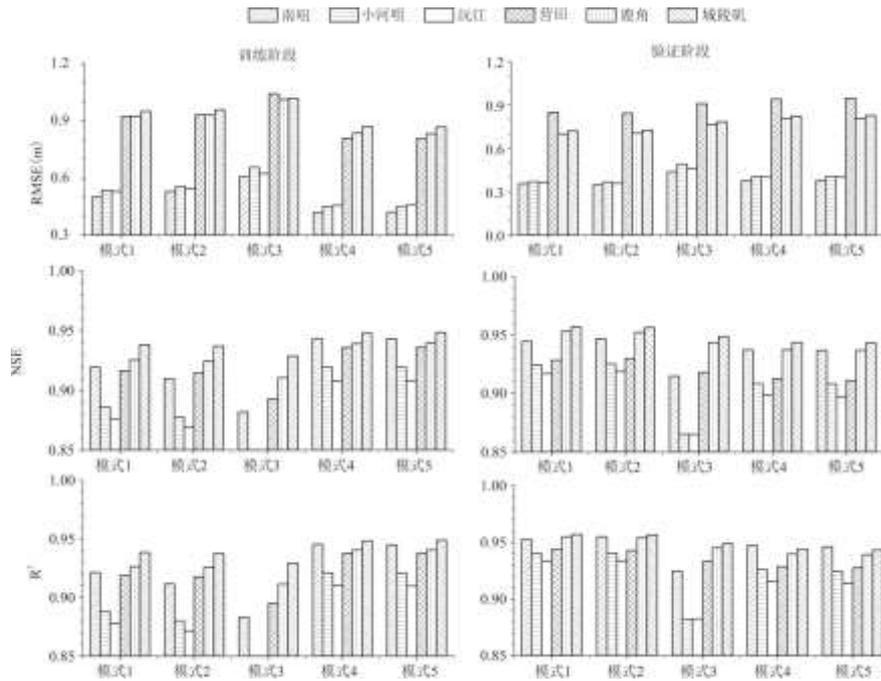


图 4 不同输入数据处理方案的模拟结果比较

表 1 LSTM 和 GRU 水位模拟模型评估结果

	方法	评价指标	南咀	小河咀	沅江	营田	鹿角	城陵矶
训练阶段	LSTM	RMSE	0.41	0.45	0.45	0.81	0.83	0.86
		NSE	0.94	0.92	0.91	0.94	0.94	0.95
		R ²	0.95	0.92	0.91	0.94	0.94	0.95
	GRU	RMSE	0.52	0.55	0.56	0.91	0.91	0.92
		NSE	0.91	0.88	0.86	0.92	0.93	0.94
		R ²	0.94	0.91	0.89	0.93	0.93	0.94
验证阶段	LSTM	RMSE	0.37	0.40	0.40	0.93	0.81	0.84
		NSE	0.94	0.91	0.90	0.91	0.94	0.94
		R ²	0.95	0.93	0.92	0.93	0.94	0.94
	GRU	RMSE	0.40	0.40	0.41	0.99	0.86	0.84
		NSE	0.93	0.91	0.89	0.90	0.93	0.94
		R ²	0.94	0.92	0.90	0.92	0.94	0.94

为了更直观的比较 LSTM 和 GRU 的性能，绘制了西、南、东洞庭湖三大湖区代表站点的预测水位图，如图 5。总体上，LSTM 和 GRU 总体上都能捕捉到水位的突变，不同湖区水位的模拟值与实测值之间的峰、谷值都能够一一对应，水位变化曲线也能够较好地吻合。LSTM 和 GRU 也能较好地模拟洞庭湖特征水位的变化，但相比枯水期水位的模拟，对洪峰水位预测性能更好。

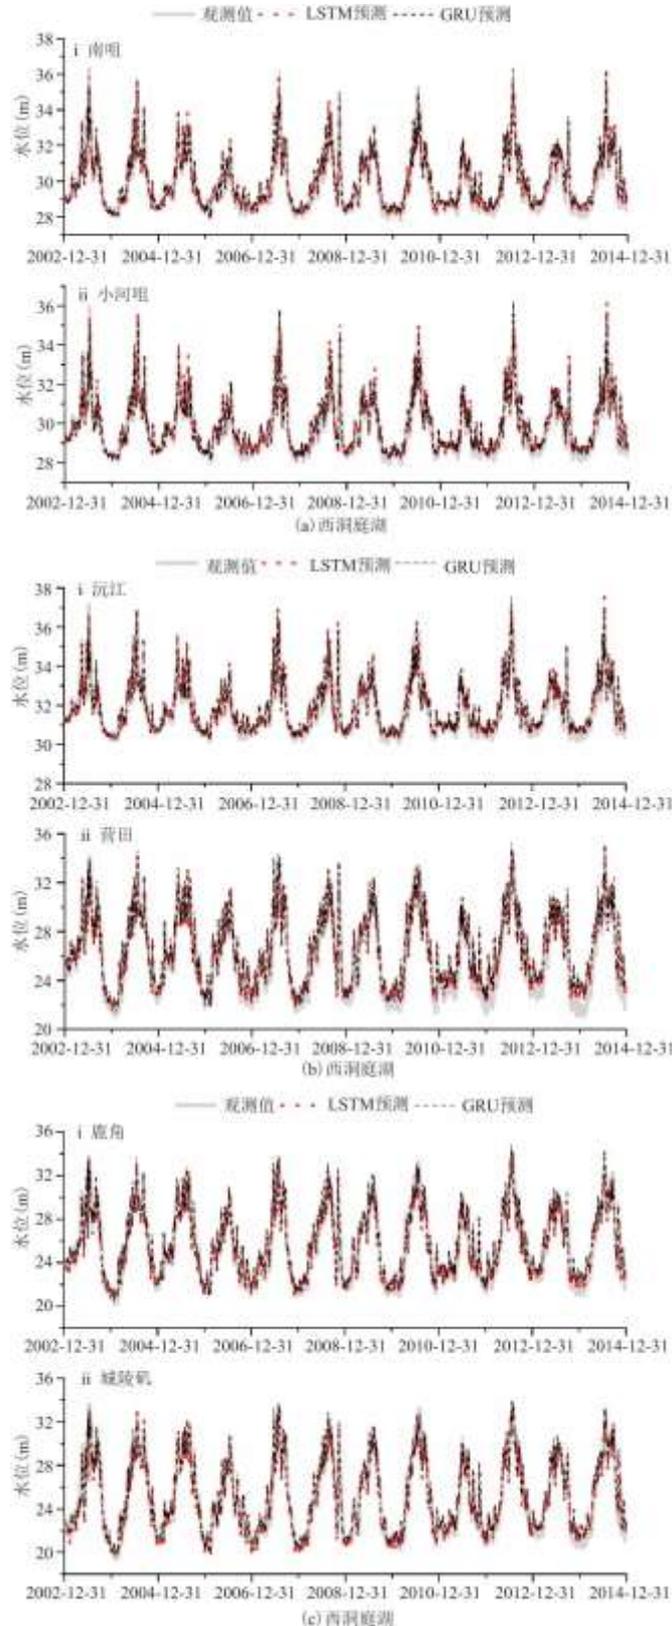


图 5 不同湖区代表站水位模拟

对神经网络模型进行优化就是使目标函数即损失函数最小化的过程。LSTM 和 GRU 在对洞庭湖水进行多步提前预测时都能得到不错的结果，两种模型均能快速收敛。但因为 GRU 本质上是一种简化了的 LSTM，内部参数较少，更容易收敛。GRU 在训练过程中比 LSTM 进步更快，在进行第 30 轮递归计算时 GRU 模型就基本收敛，且 RMSE 值明显低于 LSTM，后者要进行到第 60 轮之后。从学习曲线来看，GRU 比 LSTM 更高效。我们的结论与 Zhang 等^[21]利用这两种方法对城市的污水管道流量进行预测时一致，说明无论是人工控制的小流域环境还是自然条件下的复杂流域系统，GRU 与 LSTM 总能表现出这种特征。这是因为 GRU 的内部结构更简化，因而具有更快的计算速度，但在数据集很大的情况下，LSTM 表达性能会更好。对于大规模数据，模型训练会消耗较长时间，GRU 更快的收敛性和可比性可视为 LSTM 一个很好的替代方案。

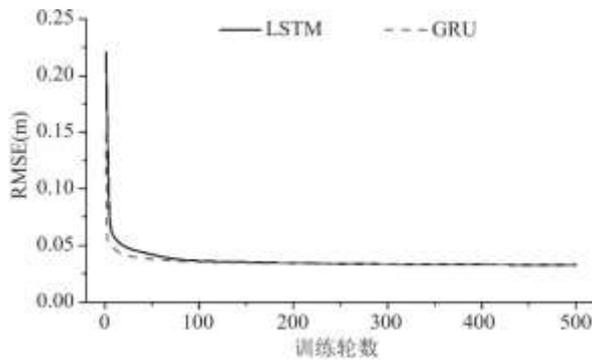


图 6 LSTM 和 GRU 学习曲线

2.4 洪水过程预报

为了考察模型预测预报性能，选取 2012 年典型洪水过程作为实际的场景来模拟洞庭湖湖区洪水预测预报过程。2012 年各站水位年变化曲线如图 7 所示。西洞庭湖和南洞庭湖西部年内水位变化峰型矮胖，南洞庭湖东部和东洞庭湖峰型尖瘦。其中，7~9 月是洞庭湖各湖区最大洪峰水位的完整涨落过程。

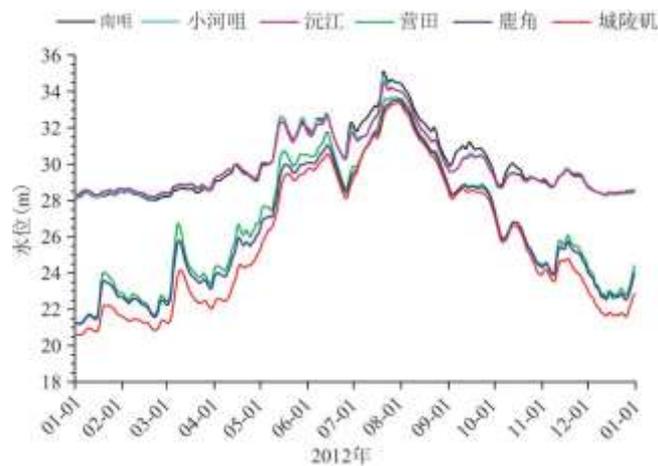


图 7 各站 2012 年水位变化过程曲线

利用已训练好的 LSTM 模型，对各站洪峰水位过程进行未来 3d 的长时间序列预测。6 站在所取时间段内的最大洪水位分别是

35.08、34.91、34.49、33.68、33.52和33.38m, 洪水位的预测值与实际洪水位的差值随着预测期的延长总体上虽呈增大趋势(表2), 但最大相对误差均能控制在5%以内, 模型对特征水位的预测精度较高。另外, 模型具有很好的外延预测能力, 随着预测期的延长各站水位绝对误差和相对误差都相对较小, 未发生明显的变化。洞庭湖水文情势复杂, LSTM神经网络可准确预测预报期长达3d的洞庭湖水位, 可为有关部门开展防洪抗旱控制工作提供科学合理的指导。

表2 未来第1、2、3d水位预测的模型评估结果

	误差	南咀	小河咀	沅江	营田	鹿角	城陵矶
未来第1d	绝对误差(m)	0.089	0.148	0.077	-0.211	-0.402	-0.366
	相对误差(%)	0.30	0.49	0.26	-0.79	-1.55	-1.45
	最高水位差值	0.86	1.00	0.94	0.86	0.42	0.25
未来第2d	绝对误差(m)	0.094	0.131	0.075	-0.211	-0.415	-0.371
	相对误差(%)	0.31	0.44	0.25	-0.79	-1.60	-1.47
	最高水位差值	0.90	1.11	1.03	1.07	0.64	0.44
未来第3d	绝对误差(m)	0.076	0.139	0.088	-0.225	-0.416	-0.399
	相对误差(%)	0.25	0.46	0.29	-0.84	-1.60	-1.58
	最高水位差值	0.83	0.92	1.00	1.14	0.72	0.59
年平均水位		30.06	29.98	29.97	26.68	25.95	25.21

一次洪水发生要经历涨水期, 洪水期和退水期3个过程。模型能够完美地捕捉到水位的变化特性(图8)。总的来说, 涨水期未来1~3d的预测水位值要大于实际观测值, 洪水期水位模拟效果非常好, 而退水期的预测水位要明显低于实际水位。退水期南洞庭湖东部和东洞庭湖的预测水位与观测值之间的差值要显著大于西洞庭湖和南洞庭湖西部的预测水位与其观测值之间的差值。何征等^[34]研究了江湖水量交换对洞庭湖水情变化的影响, 发现枯水期湖泊出流缓慢是城陵矶出口处长江水位上升对洞庭湖产生顶托作用的响应。同理, 在退水期, 长江对南洞庭湖东部和东洞庭湖水位的影响逐渐加大。模型没能完全掌握这种水文特征, 认为湖区水位会迅速降低, 但实际退水过程中, 由于长江干流此时才进入汛期, 洞庭湖出水口段的长江水位较高, 江湖水位比降小, 受到长江对湖泊的顶托作用, 南洞庭湖东部和东洞庭湖的湖泊水位是慢慢下降的。

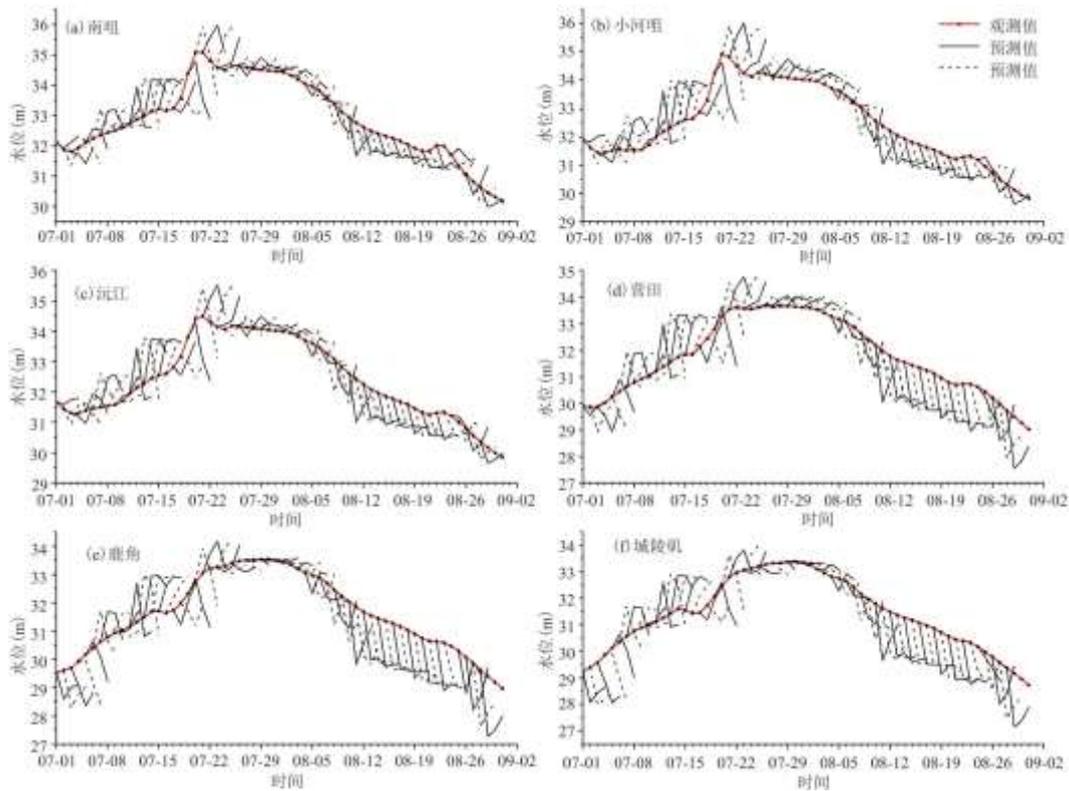


图 8 各站 2012 年最大洪峰水位模拟结果

注：为了增强可视化效果，将前后两天的预测值利用黑色实线和虚线间隔表示。

3 结论与讨论

3.1 结论

以洞庭湖为研究对象，构建了 LSTM 和 GRU 两种神经网络模型对洞庭湖的水位进行了模拟预测，并得到以下结论：

(1) 利用宜昌站前 3d、石门前 2d、湘潭、桃江、桃源三站前 1d 流量，能更准确地预测洞庭湖不同湖区未来 1d 的水位。各水位站水位预测的 RMSE 值为 0.41~0.86m, NSE 和 R^2 均为 0.91~0.95。

(2) LSTM 和 GRU 两种神经网络对洞庭湖水位的预测性能都很好。GRU 计算更高效，可视为 LSTM 一个很好的替代方案。但由于洞庭湖水位受到长江和流域“四水”的双重影响，水文情势复杂，LSTM 模拟模型的预测精度较高。

(3) 模型能较好地捕捉复杂的特征水位变化特性，具有非常好的多步长时间序列预测能力。对洪水位的准确预报能够为有关部门开展防洪控制工作提供科学合理的指导。

3.2 讨论

LSTM 和 GRU 适合于处理时间序列中间隔或延迟非常长的事件，能够在复杂的水文时间序列问题中显示其突出的优势。对比一般的神经网络，LSTM 和 GRU 网络收敛速度且不容易发生梯度消失的情况。这是因为它们独特的门控结构通过偏置和相关参数

来实时和灵活的调整激活函数的输入,可以根据与模型相关的遗忘因素来决定是否留下相应信息,有效地避免了累计误差的传递,从而大大提高模拟预测的准确性。不过仍需注意的是,深度学习网络应用需海量数据支撑,且外延性能欠佳。当历史数据不足或流域状况改变导致历史数据的模拟意义下降时,会减少网络在水文预报中的适用性。深度学习神经网络从传统意义上说属于黑箱模型,LSTM和GRU无监督的逐层训练增加了获得深度学习网络局部训练信息的困难,未来研究中我们还需进行更加深入的理论研究,更好地理解网络结构和模型。总的来说,深度学习方法在水文学领域的应用仍需进一步完善。

参考文献:

- [1]赖锡军,姜加虎,黄群.三峡工程蓄水对洞庭湖水情的影响格局及其作用机制[J].湖泊科学,2012,24(2):178-184.
- [2]HUANG Q,SUN Z,OPP C,et al.Hydrological drought at Dongting Lake:Its detection,characterization,and challenges associated with Three Gorges Dam in central Yangtze,China[J].Water Resources Management,2014,28(15):5377-5388.DOI:10.1007/s11269-014-0807-8.
- [3]YU Y,MEI X,DAI Z,et al.Hydromorphological processes of Dongting Lake in China between 1951 and 2014[J].Journal of Hydrology,2018,562:254-266.DOI:10.1016/j.jhydrol.2018.05.015.
- [4]刘娜,王克林,段亚锋.洞庭湖景观格局变化及其对水文调蓄功能的影响[J].生态学报,2012,32(15):40-49.
- [5]YUAN Y,ZENG G,LIANG J,et al.Effects of landscape structure,habitat and human disturbance on birds:a case study in East Dongting Lake wetland[J].Ecological Engineering,2014,67:67-75.DOI:10.1016/j.ecoleng.2014.03.012.
- [6]黄田,徐正刚,周立波,等.水位波动对洞庭湖越冬小天鹅家域的影响[J].生态学报,2019,39(22):1-10.
- [7]XIONG Y,WANG K.Eco-compensation effects of the wetland recovery in Dongting Lake area[J].Journal of Geographical Sciences,2010,20(3):389-405.DOI:10.1007/s11442-010-0389-1.
- [8]仲志余,徐承隆.长江中下游水文学洪水演进模型研究[J].水科学进展,1996,7(4):354-360.
- [9]胡四一,施勇,王银堂,等.长江中下游河湖洪水演进的数值模拟[J].水科学进展,2002,13(3):278-286.
- [10]赖锡军,姜加虎,黄群.洞庭湖地区水系水动力耦合数值模型[J].海洋与湖沼,2008,39(1):74-81.
- [11]孙占东,黄群,Tom L.洞庭湖流域分布式水文模型[J].长江流域资源与环境,2015,24(8):1299-1304.
- [12]LAI X,JIANG J,LIANG Q,et al.Large-scale hydrodynamic modeling of the middle Yangtze River Basin with complex river-lake interactions[J].Journal of Hydrology,2013,492(492):228-243.DOI:10.1016/j.jhydrol.2013.03.049.
- [13]NOURANI V,BAGHANAM A H,ADAMOWSKI J,et al.Applications of hybrid wavelet-Artificial Intelligence models in hydrology:A review[J].Journal of Hydrology,2014,514:358-377.DOI:10.1016/j.jhydrol.2014.03.057.
- [14]黄群,孙占东,姜加虎.三峡水库运行对洞庭湖水位影响分析[J].湖泊科学,2011,23(3):424-428.

-
- [15]HU T, YUAN P, JIN A D. Applications of Artificial Neural Network to Hydrology and Water Resources[J]. Advances in Waterence, 1995:76-81.
- [16]DAWSON C W, WILBY R L. Hydrological modelling using artificial neural networks[J]. Progress in Physical Geography, 2001, 25(1):80-108. DOI:10. 1177/030913330102500104.
- [17]LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553):436. DOI:10. 1007/s13218-012-0198-z.
- [18]YANG T, ASANJAN A A, FARIDZAD M, et al. An enhanced artificial neural network with a shuffled complex evolutionary global optimization with principal component analysis[J]. Information Sciences, 2017, 418:302-316. DOI:10. 1016/j. ins. 2017. 08. 003.
- [19]ZHANG D, LINDHOLM G, RATNAWEERA H. Use long short-term memory to enhance Internet of Things for combined sewer overflow monitoring[J]. Journal of Hydrology, 2018, 556:409-418. DOI:10. 1016/j. jhydrol. 2017. 11. 018.
- [20]ZHANG D, LIN J, PENG Q, et al. Modeling and simulating of reservoir operation using the artificial neural network, support vector regression, deep learning algorithm[J]. Journal of Hydrology, 2018, 565:720-736. DOI:10. 1016/j. jhydrol. 2018. 08. 050.
- [21]SAHOO B B, JHA R, SINGH A, et al. Long short-term memory (LSTM) recurrent neural network for low-flow hydrological time series forecasting[J]. Acta Geophysica, 2019, 67(5):1471-1481.
- [22]KRATZERT F, KLOTZ D, SHALEV G, et al. Benchmarking a Catchment-Aware Long Short-Term Memory Network (LSTM) for Large-Scale Hydrological Modeling[J]. arXiv preprint arXiv:1907. 08456, 2019.
- [23]ZHANG J, ZHU Y, ZHANG X, et al. Developing a Long Short-Term Memory (LSTM) based model for predicting water table depth in agricultural areas[J]. Journal of Hydrology, 2018, 561:918-929. DOI:10. 1016/j. jhydrol. 2018. 04. 065.
- [24]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. DOI:10. 5194/hess-22-6005-2018.
- [25]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. DOI:10. 3390/w11071387.
- [26]AKBARI ASANJAN A, YANG T, HSU K, et al. Short - Term Precipitation Forecast Based on the PERSIANN System and LSTM Recurrent Neural Networks[J]. Journal of Geophysical Research:Atmospheres, 2018, 123(22):12, 543-12, 563.
- [27]QIN J, LIANG J, CHEN T, et al. Simulating and Predicting of Hydrological Time Series Based on TensorFlow Deep Learning[J]. Polish Journal of Environmental Studies, 2019, 28(2).
- [28]谢平. 三峡工程对两湖的生态影响[J]. 长江流域资源与环境, 2017, 26(10):1607-1618.
- [29]李义天, 邓金运, 孙昭华, 等. 洞庭湖调蓄量变化及其影响因素分析[J]. 泥沙研究, 2001(6):1-7.

-
- [30]CHOLLET F.Keras:Deep learning library for theano and tensorflow[J].URL:https://keras.io/k,2015,7(8):T1.
- [31]HOCHREITER S,SCHMIDHUBER J.Long Short-Term Memory[J].Neural Computation,1997,9(8):1735-1780.DOI:10.1162/neco.1997.9.8.1735.
- [32]GERS F,SCHMIDHUBER J,CUMMINS F.Learning to Forget:Continual Prediction with LSTM[J].Neural Computation,2000,12(10):2451-2471.DOI:10.1049/cp:19991218.
- [33]CHO K,VAN MERRI ENBOER B,GULCEHRE C,et al.Learning phrase representations using RNN encoder-decoder for statistical machine translation[J].arXiv preprint arXiv:1406.1078,2014.
- [34]何征,万荣荣,戴雪,等.近30年洞庭湖季节性水情变化及其对江湖水量交换变化的响应[J].湖泊科学,2015,27(6):3-8.