

基于深度学习的潮位预报订正技术研究

吕忻¹, 丁骏²

(1. 国家海洋局东海预报中心, 上海 200136; 2. 上海市海洋监测预报中心, 上海 200062)

摘要: 引入长短期记忆神经网络(LSTM)深度学习先进算法,通过3折滑动时间序列交叉验证结合网格搜索方法确定最佳参数,构建了吴淞口潮位预报订正深度学习模型。结合风、压气象参数,对调和分析的预报潮位进行订正,得到更为准确的订正潮位,并与非线性自回归动态神经网络(NARX)浅层学习预报订正结果对比。结果表明:120 h预报潮位经LSTM模型订正后的均方根误差为0.102 m,平均绝对误差为0.084 m,订正后误差降低了52.8%;前72 h预报潮位经LSTM模型订正后误差降低了57.3%。对比发现,LSTM模型在短期和中长期潮位预报订正中均有较好表现,NARX模型在短期预报订正中表现出色。“海神”台风风暴潮过程期间,120 h、前72 h和“主振”48 h特征时段预报潮位经LSTM模型订正后,均方根误差为0.114~0.119 m,平均绝对误差为0.100~0.102 m。

关键词: 长短期记忆神经网络;深度学习;预报订正;潮位;吴淞口

中图分类号: P731.34 **文献标识码:** A **文章编号:** 1003-0239(2022)02-0070-10

1 引言

潮位预报在航运交通安全服务、港口码头靠泊作业、防汛防灾应急预警和海洋工程建设保障等领域具有广泛的应用价值。目前,基于最小二乘法的调和和分析仍是潮位预报最有力的工具^[1-2]。潮位除了受天文潮和气象因素影响外,浅水区域的非线性效应不可忽视,受其影响,潮波波形常产生显著的畸变^[3]。为有效提高潮位预报精度,解决浅水效应等问题,通过增加分潮数量,可以降低误差但效果有限^[3];与准调和法类似的“相关法”在实际应用中可以提高浅水潮位预报质量,但只有当浅水效应显著时改善效果才较明显^[4]。近年来,自回归滑动平均模型(Auto Regressive Integrated Moving Average Model, ARIMA)^[5]、卡尔曼滤波(Kalman Filter, KF)^[6]、支持向量机(Support Vector Machine, SVM)^[7]

和人工神经网络(Artificial Neural Network, ANN)^[8-9]等新兴技术在潮位预报中应用越来越广泛,取得的效果也很显著,但往往受到一些制约,如ARIMA要求序列具有平稳、正态和零均值等性质,建模中需要采用季节差分消除季节性或删除趋势项,易出现过拟合问题;KF解决实测值与预测值之间的寻优问题时,仅考虑了序列的本身特征,而潮位是受多个外部控制因素影响的,且多个因素之间又相互影响,KF不能完全反映其空间相关性;SVM训练速度慢且算法复杂,虽然其短期(提前24 h)预报明显优于传统方法,但随着时间延长,精度会逐渐下降。

随着人工智能上升为国家战略以及人工神经网络技术瓶颈的突破^[10-11],它在非线性和随机性特征序列上有强大的处理能力。Akhil等^[12]采用非线性自回归动态神经网络(Nonlinear Autoregressive Neural Network, NARX)进行芒格洛尔港口潮位周

收稿日期: 2021-03-18; 修回日期: 2021-05-24。

基金项目: 自然资源部东海局青年科学基金(202108)。

作者简介: 吕忻(1986-),女,工程师,硕士,主要从事海洋水动力研究。E-mail: lvxin@ecs.mnr.gov.cn

通讯作者: 丁骏(1986-),男,高级工程师,硕士,主要从事海洋数值预报研究。E-mail: jdjing@shou.edu.cn

预报,预报结果的均方误差为0.018 6 m,相关系数达到0.915。杨兴果^[13]应用小波变换和NARX神经网络进行钱塘江咸潮预报,与其他水动力模型相比具有更高的预测精度。Le等^[14]和Ding等^[15]应用长短期记忆神经网络(Long Short Term Memory Network, LSTM)实现了逐时洪水预报;刘亚新等^[16]基于LSTM神经网络实现了葛洲坝水电站下游水位连续6 h和上游水位连续3 h的准确预测。上述研究中的NARX^[17-18]是一种具有动态回馈机制的只有1个隐含层的浅层学习神经网络,在短期预测中具有良好的记忆功能;相比NARX,有多层隐含层节点的LSTM^[19]可以进行序列数据的有或无监督学习,具备长期与短期综合记忆的能力^[20],是深度学习中广泛使用的先进算法^[10-11]。目前,LSTM在潮位预报订正中实践较少。

本文采用LSTM方法建立了上海吴淞口潮位预报订正模型,考虑风和气压作用,基于调和分析的潮汐预报数据,订正得到更准确的潮位预报数据,并与NARX浅层学习预报结果进行对比。在台风风暴潮过程的极端条件下进行LSTM模型潮位订正应用验证,进一步研究了在欧洲中期天气预报中心(European Centre for Medium-Range Weather Forecasts, ECMWF)预报数据下开展业务化潮位预报的可行性,以为海洋智能网格预报^[21]提供技术支撑。

2 研究方法

2.1 LSTM神经网络方法

LSTM在预测时间序列数据方面具有强大的功能。LSTM网络包括输入层、隐含层(≥ 2)和输出层,并包含了不同于传统感知器体系结构的控制信息流的门和单元,即输入门、遗忘门、输出门和记忆单元状态^[20]。其网络结构见图1。

图1中, $x(t)$ 为输入值; $h(t-1)$ 和 $h(t)$ 为 $t-1$ 和 t 时刻的输出值,代表了短期记忆; $c(t-1)$ 和 $c(t)$ 为 $t-1$ 和 t 时刻的记忆单元状态,代表了长期记忆; b_i 、 b_f 、 b_c 和 b_o 表示输入门、遗忘门、记忆单元状态和输出门的偏置; W_i 、 W_f 、 W_c 和 W_o 表示输入门、遗忘门、记忆单元状态和输出门的权重矩阵; $i(t)$ 、 $f(t)$ 、 $c(t)$ 和 $o(t)$ 表示输入门、遗忘门、记忆单元状态和输




图1 LSTM神经网络结构图^[20]

Fig.1 Neural network structure of LSTM

出门的输出结果; $\text{sigmoid}(x)$ 为 $1/(1+e^x)$; $\text{tanh}(x)$ 为 $(e^x - e^{-x})/(e^x + 1 - e^{-x})$ 。

遗忘门:由前一时刻隐含层输出 $h(t)$ 和当前时刻的输入 $x(t)$,经过 sigmoid 激活函数计算得到遗忘门的输出 $f(t)$,与前一时刻记忆单元状态变量 $c(t-1)$ 求积,进而控制 $c(t-1)$ 被遗忘的程度。输入门:由 $h(t-1)$ 和 $x(t)$ 分别经过 sigmoid 和 tanh 激活函数计算得到 $i(t)$ 和新的向量 $c'(t)$,通过求积控制有多少新信息加入到状态变量,再与遗忘门部分相加得到当前时刻记忆单元变量 $c(t)$ 。输出门:经 $\text{sigmoid}(x)$ 计算得到输出门的输出 $o(t)$,与经 $\text{tanh}(x)$ 处理后的 $c(t)$ 求积,得到当前时刻隐含层输出 $h(t)$ 。LSTM的正向学习如下:

$$i(t) = \text{sigmoid}(W_i[h(t-1), x(t)] + b_i) \quad (1)$$

$$f(t) = \text{sigmoid}(W_f[h(t-1), x(t)] + b_f) \quad (2)$$

$$c(t) = f \cdot c(t-1) + i(t) \cdot \text{tanh}(W_c[h(t-1), x(t)] + b_c) \quad (3)$$

$$o(t) = \text{sigmoid}(W_o[h(t-1), x(t)] + b_o) \quad (4)$$

$$h(t) = o \cdot \text{tanh}(c(t)) \quad (5)$$

LSTM使用式(1)–(5)完成正向学习后,计算输出数据与结果数据之间的误差,误差通过反向传播进入输入门、记忆单元和遗忘门中,LSTM反向传播的推导较为复杂,此处简略。基于误差项再使用优化算法更新每个门的权重,通过设置的迭代次数,获得权重和偏置的最佳值^[20]。

2.2 NARX神经网络方法

NARX是循环动态神经网络,非常适合于非线性和非平稳时间序列的动态预测^[22],NARX神经网络定义如下:

$$y(t+1) = f[x(t), x(t-1), \dots, x(t-d_x+1); y(t), y(t-1), \dots, y(t-d_y+1); \mathbf{W}] \quad (6)$$

式中, $x(t)$ 和 $y(t)$ 表示外部输入和滞后输出变量; d_x 和 d_y 表示输入和输出延时阶数,一般 $d_x \geq 1, d_y \geq 1$; \mathbf{W} 为权重矩阵; f 为激励函数。NARX神经网络结构可分为输入层、隐含层和输出层(见图2)。

2.3 调和分析预报潮汐方法

潮汐预报采用调和分析法计算^[23],可表示为:

$$Z_t = A_0 + \sum_{i=1}^n f_i H_i \cos[q_i t + (V_0 + u)_i - g_i] \quad (7)$$

式中, Z_t 表示预报潮位; A_0 表示平均水位; f_i 表示分潮 i 的交点因子; H_i 表示分潮 i 振幅; q_i 表示分潮 i 角速度; $(V_0 + u)_i$ 表示分潮 i 初相角; g_i 表示分潮 i 迟角; f_i 和 $(V_0 + u)_i$ 与时间 t 有关; n 表示分潮数目。




图2 NARX神经网络结构图

Fig.2 Neural network structure of NARX

3 模型构建

通过LSTM框架构建深度学习模型进行吴淞口调和分析预报潮汐的订正属于监督学习问题,即以上一时间段 $(t-n, t-n+1, \dots, t-1)$ 的实测潮位、环境变量和当前时刻 t 的调和分析预报潮位和环境变量作为输入,输出 t 时刻订正潮位,再根据 t 时刻的实测潮位与 t 时刻订正潮位的已知关系,训练得到一个最优模型。该模型构建过程包括特征数据选取、预处理和参数优选等步骤。

3.1 特征数据选取

上海吴淞口位于长江口与黄浦江的交汇处,是上海港船舶通航密度最高的水域^[24],也是船舶航行受潮位影响明显的区域。吴淞口附近水域潮汐属于不规则半日潮,其潮位受到天文潮、风、气压、径流和地形等众多因素影响显现非平稳和非线性的变化特征。陈吉余等^[25]认为风和气压对长江口潮位影响明显,径流和涌浪影响甚小,可以略去不计;陈杰^[26]也认为风和气压是影响潮位的主要因子,降水和径流等对潮位虽有一定影响,但作用不大,对长江口地区来说一般可以不作考虑,故本文选择了风和气压来订正潮位。文章搜集了2019年1月3日—2020年3月31日上海吴淞验潮站整点的潮位、风速、风向资料和宝山气象站对应时刻的气压资料。采用最小二乘法^[23]对吴淞验潮站整点的实测潮位逼近,得到68个分潮调和常数 H_i 和 g_i 并计算逐小时预报潮位数据。风速和风向数据转换成 U 和 V 方向分量。

3.2 数据预处理

将调和分析预报潮位、实测潮位、 U 方向风、 V 方向风和气压时间序列数据分割成训练集、验证集和测试集。训练集用于训练模型,占数据总量的70%;验证集用于选择最优参数,占数据总量的20%,考虑实际风场预报的时效为120 h,故按120 h为单元切分验证集以用于时间序列交叉验证(Cross-validation)^[27];测试集用于评估模型效果,检验模型的泛化能力,占数据总量的10%,并按120 h为单元进行切分。数据集分割见图3。

为消除量纲对模型计算的影响,需进行输入和输出数据的归一化,归一化方法统一采用 $X_i = (X_i - \text{平均值}) / \text{标准差}$ 。

3.3 模型参数确定

神经网络的输入或输出的延时阶数(d_x 和 d_y)、隐含层的数量、神经元数量、学习率、最大迭代次数和优化算法等对时间序列预测的性能影响较大^[28-30]。目前,参数选取还没有成熟的理论,一般由经验给出。

网格搜索(Grid search)方法是一种广泛使用的搜索最佳参数的方法^[30],它根据每个参数值的数量,生成参数组合列表,并将其用于模型配置和训练。本研究采用网格搜索方法确定 LSTM 模型 5 个参

数,表 1 为 LSTM 主要参数搜索空间,其他参数选择则采用深度学习领域流行的算法,如 Adam 算法等。NARX 需要确定输入和输出的延时阶数、隐含层节点数 3 个结构参数,训练方程采用贝叶斯规则法。

为有效防止模型学习的过拟合,提高模型的泛化能力,同时考虑到时间序列数据存在的序列相关性,且不满足样本独立同分布假设的传统交叉验证前提,本文采用逐渐增加训练集长度的时间序列交叉验证^[27]和网格搜索方法确定模型参数。基本思想见图 3,即每组参数都经过 3 折时间序列交叉验证,并对 3 组评价指标均方根误差(Root Mean Square Error, RMSE)取平均数,然后找出最好评分结果对应的参数组合。最佳的参数结果见表 1。




图3 数据集分割和时间序列交叉验证

Fig.3 Data set segmentation and time series Cross-validation

表 1 模型的参数取值

Table 1 Parameter values of the model

模型	参数	取值	最佳参数
LSTM	延时阶数	[1, 3, 6, 12]	1
	隐含层数	[25, 50, 100, 200]	50
	神经元数量	[25, 50, 100, 200]	100
	学习率	[0.01, 0.005, 0.000 1]	0.005
	最大迭代次数	[100, 200, 300]	300
NARX	输入延时阶数	[1, 3, 6, 12, 24]	6
	输出延时阶数	[1, 3, 6, 12, 24]	1
	隐含层节点数	[25, 50, 100, 200]	25

4 结果验证

本文构建的LSTM深度神经网络潮位订正模型输入要素为 t 和 $t+1$ 时刻吴淞口 U 方向风、 V 方向风和气压值,以及 $t+1$ 时刻调和和分析预报潮位和 t 时刻实测潮位,共8个变量,输出结果为 $t+1$ 时刻订正潮位。将 $t+1$ 时刻订正潮位作为 $t+1$ 时刻实测潮位进行迭代得到 $t+2, \dots, t+120$ 时间序列的滚动预测结果。NARX浅层神经网络潮位订正模型输入要素为 $t, t-1, t-2, \dots, t-5$ 时刻吴淞口调和和分析预报潮位、 U 方向风、 V 方向风、气压值和 t 时刻实测潮位,订正结果输出为 $t+1$ 时刻订正潮位,再将 $t+1$ 时刻的订正潮位作为 $t+1$ 时刻的实测潮位迭代模型得到 $t+2, t+3, \dots, t+120$ 时间序列的滚动预测结果。在10%测试集中随机选择测试集1用于模型验证。

图4为LSTM模型潮位预报订正结果,从LSTM订正的潮位曲线与实测潮位对比可知,两者吻合度较高,120 h预报潮位经LSTM模型订正后RMSE为0.102 m,平均绝对误差(Mean Absolute Error, MAE)为0.084 m。LSTM订正120 h的潮位比订正前的RMSE降低了52.8%,即0.114 m,MAE减小了0.095 m。在120 h预报潮位的前72 h预报期内,调和和分析预报潮位经LSTM模型订正后RMSE为0.088 m,MAE为0.071 m,LSTM订正72 h的潮位

比订正前的RMSE降低了57.3%,即0.118 m,MAE减小了0.099 m。图4中实测潮位和天文潮差值表示的实际增减水曲线与LSTM订正潮位和天文潮差值表示的订正后增减水曲线也非常一致。综上,通过深度学习模型LSTM订正得到的潮位结果更接近真实值。

图5为NARX模型潮位预报订正结果,由NARX订正的潮位曲线与实测潮位对比可知,120 h调和和分析预报潮位经NARX模型订正后RMSE为0.244 m,MAE为0.177 m,订正后的误差与订正前接近,整体订正效果不佳;在前72 h预报期内,调和和分析预报潮位经NARX模型订正后RMSE为0.100 m,MAE为0.081 m,其订正后的误差与LSTM订正后的误差接近。这主要是因为NARX模型和LSTM模型一样,将引起潮位变化的气象要素考虑在内,具有较强的非线性拟合能力,短期预测结果较精确,但对于中长期的潮位预报来说,该模型预测精确度会随着时间的增长而逐步下降。图5中实际增减水与订正后的增减水曲线对比可知,前期拟合较好,后期差别较大,这主要是由于NARX模型只有1个隐含层,相比LSTM模型50个隐含层数来说,长期特征记忆能力不强,对72 h之后的潮位预报订正不佳,也显现出浅层学习模型的局限性。

为进一步验证LSTM模型对台风风暴潮过程的极端条件预报订正能力,本文以2020年第10号超强台风“海神”风暴潮为例,选择了2020年9月4日08时(北京时,下同)—9日08时共121时次吴淞验




图4 LSTM潮位预报订正结果

Fig.4 Correction results of tide level forecast by LSTM

潮站调和预报潮位、实测潮位、实测风的北分量、东分量和宝山气象站实测气压逐时数据进行研究。以4日08时和09时的 U 方向风、 V 方向风和气压,以及4日08时的实测潮位和4日09时的调和预报潮位作为8个输入变量,采用训练好的LSTM模型订正得到4日09时的订正潮位1个输出变量,再以09时的订正潮位作为实测潮位进行迭代订正得到120 h的LSTM订正潮位序列。

图6为LSTM模型对“海神”台风风暴潮过程预报订正结果,120 h调和预报潮位与实测潮

位之间的RMSE为0.238 m,MAE为0.196 m。120 h调和预报潮位经LSTM模型订正后的RMSE为0.119 m,MAE为0.101 m,风暴潮的订正结果较好,订正后的误差约为10 cm, RMSE减小约50%。时间序列前72 h、台风“主振”48 h(9月6日00时—7日23时)和“主振”48 h高潮时3个特征时段的误差统计见表2。LSTM订正后的“主振”高潮位误差与其他3个时段相比较,约有0.191 m误差,可见LSTM对高潮位的订正效果略显不足。




图5 NARX潮位预报订正结果

Fig.5 Correction results of tide level forecast by NARX




图6 “海神”台风风暴潮LSTM订正结果

Fig.6 LSTM correction results of storm surge caused by typhoon "Haishen"

表2 “海神”台风风暴潮LSTM预报订正误差统计

Tab.2 Error statistics of storm surge forecast with and without LSTM correction

特征时段	LSTM订正后		LSTM订正前	
	RMSE/m	MAE/m	RMSE/m	MAE/m
120 h	0.119	0.101	0.238	0.196
前72 h	0.114	0.100	0.268	0.231
“主振”48 h	0.114	0.102	0.329	0.303
“主振”48 h高潮时	0.191	0.182	0.339	0.332

5 讨论

LSTM深度神经网络潮位订正模型的验证结果体现了深度学习方法在提高潮位预报准确率方面的优势,但验证数据均采用了实测数据,即在10%测试集中随机选择的测试集1和“海神”台风风暴潮过程预报订正中选择的风和气压数据均为实测数据,本质属于“后报”。为了提高LSTM模型的业务化应用水平,对其“预报”能力作进一步讨论研究。本文选择了超强台风“海神”影响期间的风和气压预报数据,该数据来自上海市气象台订正的ECMWF预报产品,启报时间为2020年9月4日08时,预报时长为120 h,前72 h分辨率为3 h,后48 h分辨率为6 h,空间分辨率为 $0.125^{\circ} \times 0.125^{\circ}$,覆盖区域 $70^{\circ} \sim 140^{\circ} \text{E}$, $0^{\circ} \sim 55^{\circ} \text{N}$ 。通过空间插值提取得到吴淞口120 h逐时的风的北和东分量以及气压预报数据后带入LSTM模型订正。将应用实测风和气压的

订正结果与ECMWF预报的风和气压订正结果进行对比,结果见图7。由图可知,预报风和气压的订正结果与实测结果误差相近,RMSE(见图7a)和MAE(见图7b)略低于实测风和气压订正的误差,可以将训练所得的LSTM模型用于业务化预报中。

参数调优是深度学习研究中最耗费成本的部分之一^[30],很多论文都包括一系列令人惊奇的结果,这归功于研究人员花费大量的时间调整了参数空间。参数调节时一般采用经验方法或者控制实验的方法,即每次只调整一个参数,然后观察loss变化,如崔巍等^[31]通过比较不同神经元数量对验证数据预报结果的影响来确定合适的神经元数量,并依赖经验确定LSTM最佳学习率为0.01。本文采用的网格搜索方法是一种广泛采用搜索最佳参数的方法,本质也是控制实验的方法,Abbasimehr等^[32]和杜维仲等^[33]使用该方法搜索LSTM网络的最佳参数。实践中发现,该方法会受到计算能力和时间的约束。网格搜索与交叉验证结合可以更有效地进行




图7 实测与预报风、气压数据订正结果误差对比

Fig.7 Correction error comparison of measured and forecast pressure and wind data

参数评价,针对研究数据的特点采用传统K折交叉验证评估模型的研究较多^[33-34]。本文采用时间序列交叉验证较新颖,将验证集设在训练集之后并进行3折滑动是非常重要的,不仅考虑了时间序列的自相关性和非独立性,而且模型结果表现较优,可以进行实践应用。

另外,本文基于文献调研选择了风和气压进行调和和分析预报潮位订正,订正后的效果较好,误差在10 cm左右。除了这两个要素外,潮位还受到径流、降水和地形等其他因素影响,将其他因素考虑在内,也是今后研究的重要方向。LSTM在“海神”台风风暴潮订正中,“主振”48 h高潮位订正的RMSE为0.191 m,MAE为0.182 m,订正效果略显不足,而风暴潮过程的最显著特征就是伴随显著增减水和极端增水过程,在海洋预警报工作中极值高潮位预报尤为重要。今后可在本文研究基础上进一步尝试选择历史风暴潮实测数据以及与之相关的台风、温带气旋、寒潮等特征因子,如台风移行路径、移动速度、台风尺度、气压和风力等,建立基于深度学习的风暴潮预报研究。

6 结论

本文使用LSTM深度学习技术构建吴淞口潮位预报订正模型,对120 h的实时潮位和“海神”台风风暴潮过程潮位进行订正,并与NARX浅层学习预报订正结果对比。结论如下:

(1)120 h预报潮位经LSTM模型订正后RMSE为0.102 m,MAE为0.084 m,订正后的潮位误差降低了52.8%,NARX模型订正后的误差与订正前接近,NARX在中长期潮位预报订正中效果欠佳。前72 h预报潮位经LSTM模型订正后RMSE为0.088 m,MAE为0.071 m,相比订正前准确度提高57.3%,NARX与LSTM订正的效果接近,两者在短期潮位订正中较精确。

(2)LSTM在120 h的“海神”台风风暴潮订正中,RMSE为0.119 m,MAE为0.101 m,订正后误差减小约50%,与前72 h和“主振”48 h台风风暴潮特征时段订正的误差相当,“主振”48 h高潮位订正的RMSE为0.191 m,MAE为0.182 m,订正效果略显不足。

(3)采用网格搜索与时间序列交叉验证方法获得的最佳参数结果可信,将验证集设在训练集之后并进行3折滑动,有利于提高潮位订正精度。

(4)采用深度学习技术订正潮位,为海洋智能化预报研究提供一个重要而有益的视角,精准的潮位预报产品能够更好地服务于航运交通、防灾减灾和海上作业等领域。

参考文献:

- [1] Doodson A T. The analysis and predictions of tides in shallow water [J]. *International Hydrographic Review*, 1957, 33(1): 85-126.
- [2] 叶琳. 潮汐预报与服务[J]. *海洋预报服务*, 1985(1): 74-76.
Ye L. Tide forecast and service[J]. *Marine Forecast Service*, 1985 (1): 74-76.
- [3] 方国洪,于克俊. 浅水港口潮汐预报的一个方法[J]. *海洋与湖沼*, 1981, 12(5): 383-390.
Fang G H, Yu K J. A method for predicting the tides of shallow-water ports[J]. *Oceanologia et Limnologia Sinica*, 1981, 12(5): 383-390.
- [4] 黄辰虎,刘雁春,暴景阳,等. 相关法在提高浅水港口潮汐预报质量方面的应用[J]. *海洋测绘*, 2004, 24(3): 9-11.
Huang C H, Liu Y C, Bao J Y, et al. Increasing the quality of tide prediction in Netric port with correlation[J]. *Hydrographic Surveying and Charting*, 2004, 24(3): 9-11.
- [5] Box G E P, Jenkins G M, Reinsel G C, et al. Time series analysis: forecasting and control, 5th edition[J]. *Journal of the Operational Research Society*, 2015, 22(2): 199-201.
- [6] Yen P H, Jan C D, Lee Y P, et al. Application of Kalman filter to short-term tide level prediction[J]. *Journal of Waterway, Port, Coastal, and Ocean Engineering*, 1996, 122(5): 226-231.
- [7] 柳成,尹建川. 一种高精度的短期潮汐预报模型[J]. *上海海事大学学报*, 2016, 37(3): 74-80.
Liu C, Yin J C. A high-accuracy short-term tide prediction model [J]. *Journal of Shanghai Maritime University*, 2016, 37(3): 74-80.
- [8] Meena B L, Agrawal J D. Tidal level forecasting using ANN[J]. *Procedia Engineering*, 2015, 116: 607-614.
- [9] Lee T L, Jeng D S. Application of artificial neural networks in tide-forecasting[J]. *Ocean Engineering*, 2002, 29(9): 1003-1022.
- [10] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. *Nature*, 2015, 521 (7553): 436-444.
- [11] Schmidhuber J. Deep learning in neural networks: an overview[J]. *Neural Networks*, 2015, 61: 85-117.
- [12] Salim A M, Dwarakish G S, Liju K V, et al. Weekly prediction of tides using neural networks[J]. *Procedia Engineering*, 2015, 116: 678-682.
- [13] 杨兴果. 钱塘江河口咸潮入侵预警研究[D]. 杭州: 浙江大学, 2014.

- Yang X G. Saltwater intrusion warning research in Qiantang estuary[D]. Hangzhou: Zhejiang University, 2014.
- [14] 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.
- [15] 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.
- [16] 刘亚新, 樊启祥, 尚毅梓, 等. 基于 LSTM 神经网络的水电站短期水位预测方法[J]. *水利水电科技进步*, 2019, 39(2): 56-60, 78.
- Liu Y X, Fan Q X, Shang Y Z, et al. Short-term water level prediction method for hydropower station based on LSTM neural network[J]. *Advances in Science and Technology of Water Resources*, 2019, 39(2): 56-60, 78.
- [17] Leontaritis I J, Billings S A. Input-output parametric models for non-linear systems Part I: deterministic non-linear systems[J]. *International Journal of Control*, 1985, 41(2): 303-328.
- [18] Billings S A. Models for linear and nonlinear systems[M]//Billings S A. *Nonlinear System Identification: NARMAX Methods in the Time, Frequency, and Spatio-Temporal Domains*. Hoboken: John Wiley & Sons, Ltd., 2013.
- [19] Hochreiter S, Schmidhuber J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [20] Greff K, Srivastava R K, Koutník J, et al. LSTM: a search space odyssey[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28(10): 2222-2232.
- [21] 方正飞. 智能网格化推动海洋预报更精确[N]. *中国海洋报*, 2017-06-16(001).
- Fang Z F. Intelligent grid promotes ocean forecast more accurate [N]. *China Ocean News*, 2017-06-16(001).
- [22] Diaconescu E. The use of NARX neural networks to predict chaotic time series[J]. *WSEAS Transactions on Computer Research*, 2008, 3(3): 182-191.
- [23] 陈宗镭. 潮汐学[M]. 北京: 科学出版社, 1980.
- Chen Z Y. *Tidology*[M]. Beijing: Science Press, 1980.
- [24] 徐文龙, 姜海燕, 张翼翔. 吴淞口警戒区通航风险分析[J]. *水运管理*, 2020, 42(1): 34-36.
- Xu W L, Jiang H Y, Zhang Y X. Analysis on navigation risk in Wusongkou precautionary area[J]. *Shipping Management*, 2020, 42(1): 34-36.
- [25] 陈吉余, 沈焕庭, 恽才兴, 等. 长江河口动力过程和地貌演变 [M]. 上海: 上海科学技术出版社, 1990.
- Chen J Y, Shen H T, Yun C X, et al. Dynamic process and morphological evolution in the Changjiang Estuary[M]. Shanghai: Shanghai Scientific and Technical Publishers, 1990.
- [26] 陈杰. 短期潮位预报分析探讨[C]//中国航海学会航标专业委员会测绘学组 2008 年学术研讨会论文集. 北京: 中国航海学会, 2008: 478-487.
- Chen J. Analysis and discussion of short-term tidal level forecast [C]//*Proceedings of Academic Exchange at the Symposium of Surveying and Mapping Group, Navigation Mark Professional Committee*. Beijing: Chinese Nautical Association, 2008: 478-487.
- [27] 吴喜之, 刘苗. 应用时间序列分析 R 软件陪同[M]. 2 版. 北京: 机械工业出版社, 2018.
- Wu X Z, Liu M. *Applied time series analysis with R*[M]. 2nd ed. Beijing: China Machine Press, 2018.
- [28] Ribeiro G H T, De M Neto P S G, Cavalcanti G D C, et al. Lag selection for time series forecasting using Particle Swarm Optimization[C]//*The 2011 International Joint Conference on Neural Networks*. San Jose: IEEE, 2011: 2437-3444.
- [29] Hermans M, Schrauwen B. Training and analyzing deep recurrent neural networks[C]//*Proceedings of the 26th International Conference on Neural Information Processing Systems*. Lake Tahoe: ACM, 2013: 190-198.
- [30] Reimers N, Gurevych I. Optimal hyperparameters for deep LSTM-networks for sequence labeling tasks[J]. *arXiv*: 1707.06799, 2017.
- [31] 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.
- Cui W, Gu R H, Chen B Y, et al. Comparison of BP and LSTM neural network for hydrologic forecasting of a small watershed in Fujian[J]. *Pearl River*, 2020, 41(2): 74-84.
- [32] Abbasimehr H, Shabani M, Yousefi M. An optimized model using LSTM network for demand forecasting[J]. *Computers & Industrial Engineering*, 2020, 143: 106435.
- [33] 杜维仲, 王硕. 基于 LSTM 的辅助动力装置系统辨识与仿真[J]. *计算机测量与控制*, 2020, 28(2): 157-161.
- Du W Z, Wang S. System identification and simulation of auxiliary power plant based on LSTM[J]. *Computer Measurement & Control*, 2020, 28(2): 157-161.
- [34] 盛敏, 李兰. 基于动作主视图和 LSTM 网络模型的人体行为识别[J]. *安庆师范大学学报(自然科学版)*, 2020, 26(1): 73-76.
- Sheng M, Li L. Human behavior recognition based on LSTM network model and front action view[J]. *Journal of Anqing Normal University (Natural Science Edition)*, 2020, 26(1): 73-76.

Study on the correction technology of tide level forecast based on deep learning

LYU Xin¹, DING Jun²

(1. East China Sea Forecasting Center, SOA, Shanghai 200136 China; 2. Shanghai Ocean Monitoring and Forecasting Center, Shanghai 200062 China)

Abstract: In this paper, a deep learning model to correct the tide level prediction in Wusongkou area is established based on the advanced long short term memory (LSTM) neural network and the best parameters determined by 3-fold cross validation of sliding time series and grid search method. The forecast tide level of harmonic analysis is corrected with higher accuracy using wind and pressure meteorological parameters, and is compared with the correction result of the nonlinear autoregressive exogenous (NARX) dynamic neural network. The results show that the root mean square error (RMSE) and the mean absolute error (MAE) of the 120 h forecast tide level corrected by LSTM model is 0.102 m and 0.084 m, respectively, and the error is reduced by 52.8%. Moreover, the error of 72 h forecast tide level corrected by LSTM model is reduced by 57.3%. By comparison, it is found that the LSTM model performs well in the correction of short-term and medium-term and long-term tide level forecast, while the NARX model performs well only in the correction of short-term forecast. During the storm surge process caused by typhoon Haishen, the RMSE and MAE of the forecast tide level corrected by LSTM model for the characteristic periods of 120 h, the first 72 h and 48 h are 0.114~0.119 m and 0.100~0.102 m.

Key words: long short term memory; deep learning; forecast correction; tide level; Wusongkou area