

基于机器学习的广东海域模式风暴潮数据订正及评估

俞重阳¹, 张露²

(1. 河海大学海洋学院, 江苏 南京 210098; 2. 国家海洋环境预报中心, 北京 100081)

摘要: 研究基于欧洲中期天气预报中心的ERA5再分析风场与海平面气压数据, 驱动ADCIRC模式构建了广东省2024年两次风暴潮过程的逐小时风暴潮数据集。针对ADCIRC模式在广东沿岸模拟存在的系统误差, 发展了一种基于随机森林回归的机器学习订正方法。通过构建包含模拟增水、潮位、风增水、风速等17项物理特征及其衍生交互项的特征体系, 建立了具有明确物理意义的误差订正模型。训练结果表明: 模型在1377个样本上表现出良好的学习能力, 训练集与测试集的 R^2 分别为0.72和0.65, RMSE分别为16.69和21.24, 相关系数分别达到0.86和0.81。实例测试显示: 模型对2024年9月过程的高风速个例的改进率为11.65%, 对2024年11月过程的低风速个例的改进率达48.08%, 平均改进率为29.87%。该机器学习订正方法能有效降低ADCIRC模式的系统误差, 在低风速条件下订正效果尤为显著。

关键词: 广东海域; 风暴潮; 数值模拟; 机器学习

中图分类号: P731.23 **文献标识码:** A **文章编号:** 1003-0239(2026)03-0031-11

0 引言

风暴潮作为一种由强烈大气扰动(如热带气旋、温带气旋、冷锋的强风作用和气压骤变)及波浪增水叠加引起的海面异常升高现象, 其形成机制涉及多物理场的复杂耦合。风浪、涌浪叠加在天文潮和风暴潮之上, 共同引发的沿岸海水暴涨常常酿成巨大潮灾^[1-2]。随着我国沿海地区经济持续发展, 风暴潮灾害已经成为我国主要自然灾害之一, 直接影响沿海地区社会经济发展和人民生活。因此, 准确开展风暴潮预报对保障沿海地区人民生命财产安全具有重要意义^[3-5]。

广东海域位于南海北部, 地理位置独特, 水文气象条件复杂, 是我国风暴潮灾害的频发区。从海洋动力学角度来看, 广东海域面向开阔南海, 大陆架地形相对平缓, 为风暴潮能量的积累和传播提供了天然条件。境内海岸线蜿蜒曲折、岛屿众多, 形成了粤东岬角、珠三角河口湾等众多隐蔽港湾与开

放岸段, 这类地貌特征显著影响风暴潮的传播路径和增水幅度。从气象条件分析, 夏秋季节西北太平洋台风活动频繁, 台风西行登陆或沿岸北上诱发电广东海域风暴潮的主要动力因素。此外, 夏季盛行西南季风、冬季盛行强东北季风, 持续风应力会对沿岸增水产生显著影响, 这种季节性风场变化与天文潮的相互作用, 进一步增加了风暴潮预报的复杂性。

传统风暴潮研究多聚焦于单一台风过程模拟, 这类方法虽然能够详细刻画特定台风过程中的动力机制, 但难以揭示区域风暴潮的统计规律和长期变化特征。因此, 如果利用高时空分辨率风暴潮数值产品, 评估气候变化背景下中国沿海风暴潮灾害及其时空变化特征, 必须先对风暴潮数值模拟结果开展全面检验, 不能仅针对台风登陆前后单次风暴潮过程进行验证^[4]。随着气象再分析技术快速发展, 构建长时间序列、高时间分辨率的风暴潮数据集已成为可能, 对理解区域风暴潮统计特征与发生

收稿日期: 2025-11-30。

基金项目: 国家自然科学基金项目(42425601)。

作者简介: 俞重阳(2001-), 男, 硕士在读, 主要从事海气相互作用和热带气旋研究。E-mail: chongyangyu@hhu.edu.cn

规律具有一定意义。再分析数据通过同化多源观测资料、提供时空连续的大气和海洋状态变量,为风暴潮统计研究奠定了基础。机器学习方法对解决具有一定内在规律、机理不明确的问题特别有效,能够准确描述因变量与多个自变量间的非线性关系,为揭示台风风暴潮强度和台风参数间的非线性关系提供了有效方案^[6]。目前,随机森林(Random Forest)、决策树等机器学习算法和人工神经网络等深度学习方法,已在风暴潮强度预测中得到有效应用。侯琪等^[6-7]基于随机森林模型,选取台风中心最大风速、中心最低气压等8个台风参数开展风暴潮强度预测;刘珍等^[8-12]基于神经网络,结合黄渤海模式数据对实现区域风暴潮预报。

在欧洲中期天气预报中心(European Centre for Medium-Range Weather Forecasts, ECMWF)发布的各类再分析产品中,ERA5(ECMWF Reanalysis v5)以其 $0.25^{\circ} \times 0.25^{\circ}$ 空间分辨率和逐小时时间分辨率,已成为当前驱动风暴潮模式的可选强迫场之一。ERA5不仅继承了前代ERA-Interim产品的优点,还在数据同化方法、模型物理过程和输入数据等方面进行了显著改进^[13]。

本研究采用2024年ERA5逐小时10 m风场与海平面气压数据,驱动高级环流模型(The Advanced Circulation Model, ADCIRC)构建广东海域2024年两次风暴潮过程逐小时数据集。由于ADCIRC在处理复杂岸线和非结构网格方面具备独特优势,因此能够更好地适配广东海域复杂的地理特征^[14]。自Luettich等^[15]建立ADCIRC模型的理论框架以来,其已被广泛应用于各类风暴潮研究,尤其在飓风/台风影响下的海域表现出良好的模拟能力^[16]。本研究基于广东沿岸12个潮位站水位观测数据,构建基于随机森林的机器学习订正算法,旨在有效降低模式系统误差,提升风暴潮模拟结果的准确性和可靠性。

1 数据和方法

1.1 风暴潮模式和数据来源

为精确模拟风暴潮在整个广东海域的传播和演化过程,本研究选用ADCIRC作为数值模拟平台。ADCIRC是一个基于有限元方法的海岸海洋环

流模型,特别适用于模拟潮汐、风暴潮和陆架环流等物理过程。其核心优势在于采用非结构三角形网格,能够灵活适应复杂的海岸线和海底地形,在近岸区域实现更高的空间分辨率,同时在开阔海域保持较低的计算成本。

本研究构建的计算区域覆盖 $110^{\circ} \sim 122^{\circ} \text{E}$, $18^{\circ} \sim 26^{\circ} \text{N}$,完整包含了影响广东海域的主要天气系统和海洋动力过程。网格系统共包含55 913个计算节点和108 713个网格单元,网格分辨率从开阔海域的约10 km逐渐加密至近岸区域的200 m左右。这种变分辨率设计确保了在关键区域(如珠江口、雷州半岛等)获得足够的模拟精度,同时控制整体计算量。参数设置采用冷启动、球坐标、二维模式、混合底摩擦形式、考虑有限振幅项并采用干湿网格法、科氏参数基于 β 平面近似、考虑天文潮汐作用,时间步长为0.6 s,满足CFL条件要求,由K1, O1, P1, Q1, N2, M2, S2, K2等8个分潮驱动计算。采用1997—2001年经国家测绘局海岸线资料订正后的比例尺为1:250 000的海岸线数据。研究区域的水深数据由 $100^{\circ} \sim 137^{\circ} \text{E}$, $5^{\circ} \text{S} \sim 52^{\circ} \text{N}$ 范围内分辨率为 $2' \times 2'$ 的全球水深数据插值得到。

为验证模式性能并开展后续的机器学习订正研究,本文采用覆盖广东沿岸的12个潮位站(珠海、南渡、湛江、水东、三灶、闸坡、盐田、汕头、惠州、北津、碙洲和广州)的观测数据。采用这些站点充分考虑了广东海域的地理特征,涵盖开阔海岸、海湾、河口等不同地形条件,能够代表区域风暴潮的空间变化特征。所有潮位站数据均经过严格的质量控制,包括异常值剔除、时间一致性检查和缺失数据插值补齐,确保数据的可靠性和连续性。

在气象强迫场方面,采用ECMWF的ERA5逐小时再分析数据驱动风暴潮模式。ERA5数据集提供10 m高度的 U/V 风场分量、海平面气压、2 m气温和露点温度、地表气压等关键变量。与早期再分析产品相比,ERA5在时空分辨率、同化方法和物理过程参数化方面均有显著改进,特别是在表征台风涡旋结构和强度方面具有明显优势。

本研究除计算模拟值和实测值的相关系数(R)、均方根误差(Root Mean Square Error, RMSE)和平均绝对误差外,特别关注了最大风暴增水的模拟效果,该指标对海洋防灾减灾最为关键。验证时




图1 研究所用的潮位站位置

Fig.1 Locations of tide gauge stations used in the study

间覆盖2024年全年,重点分析9月和11月两次典型风暴潮过程,两次过程分别对应高风速和低风速条件下的风暴潮特征。

1.2 数值模拟检验

风暴潮模式计算时段为2024年1月1日—12月31日,完整覆盖年内所有显著风暴潮事件。图2为2024年9月4—8日(称为9月过程)、2024年11月9—13日(称为11月过程)两次风暴潮事件期间,广东沿岸主要潮位站的实测潮位与模拟潮位对比结果。从动力机制角度分析,9月过程主要受台风“摩羯”影响,该台风在南海北部形成强而集中的风场,为典型的风应力驱动主导型风暴潮;11月过程则与冷空气活动密切相关,表现为大范围、长持续时间的天气尺度风场作用。

从验证结果来看,模拟数据与实测数据在相位和变化趋势上一致性良好,能够准确捕捉各站点风暴潮的起涨、到达峰值和消退过程。9月过程中,模式成功再现了台风过境期间快速增水和缓慢退水的特征,峰值出现时间与实测偏差基本在1 h以内;11月过程中,模式较好地模拟了冷空气持续作用下风暴潮的多峰结构和长持续时间特征。

最大风暴增水检验是评估模式性能的关键指标。统计分析表明,9月过程中风暴潮模拟增水与实测增水的相关系数为0.74,最大增水的平均相对误差为35.6%。这一结果说明,模式在高风速条件下能够较好地再现风暴潮的空间分布和时间变化特征。相比之下,11月过程中模拟效果有所下降,相关系数为0.54,最大增水平均相对误差达66.9%。

这种差异反映了模式在不同天气系统驱动下的性能变化。

从误差分布特征来看,9月过程误差主要表现为系统性低估,11月过程则随机误差成分显著,表明弱风条件下,模式对次网格尺度过程和边界层参数化方案的不确定性更加敏感。此外,地理分布分析显示,半封闭海湾内站点(如广州、南渡)的模拟效果普遍优于开阔海岸站点,这可能与开边界条件的设置和局部地形效应的模拟精度有关。这些验证结果明确反映出ADCIRC模式在广东海域应用的局限性:模式虽然能够再现风暴潮的基本变化趋势,但增水数值的相对误差较大,在复杂天气条件和特殊地形海域尤为明显。这表明开展有效误差订正十分必要,基于模式输出和环境特征能进一步减小模拟误差,提升模拟产品的实用价值。此外,本研究ADCIRC模式所用驱动风场来源于ERA5数据集,其本身存在台风风速低估问题,这也是造成误差的不可忽视的原因之一。

2 值模拟结果订正

2.1 模型与特征数据的选择

在风暴潮模拟订正方法研究中,机器学习算法的选择需综合考虑问题特点和算法性能。随机森林回归模型因其在处理复杂非线性关系、抵抗过拟合以及开展特征重要性分析方面具备优势,因此被选为核心算法。从计算智能角度来看,随机森林通过集成多个决策树,能够有效捕捉ADCIRC模式输出与实测增水之间复杂的物理关系。其内置的袋




图2 广东沿岸潮位站风暴潮观测(•)与模拟结果(—)对比

Fig.2 Comparison of observed (•) and simulated (—) storm surge at tide gauge stations along the Guangdong coast

外误差(Out-of-Bag Error)估计功能为模型性能评估提供客观指标,特征重要性排序则从数据驱动视角揭示了影响风暴潮误差的关键因素。随机森林另一个重要优势是对数据分布无严格假设,能够适配风暴潮数据常见的非正态分布和异常值特征。

本研究以 Python 作为分析平台,基于 Scikit-learn 库实现机器学习模型的构建与训练;采用 NumPy 和 Pandas 开展数值模拟数据预处理与特征工程;通过 Matplotlib 和 Seaborn 库完成可视化分析。在随机森林回归模型核心参数设置上,设置决策树数量为 300,最大树深度为 20,最小分割样本数为 10,最小叶节点样本数为 5。

特征工程是机器学习订正效果优劣的关键环节。本研究摒弃了传统的站点特异性信息,专注于构建纯物理特征体系。基础物理量包括模拟增水、天文潮位、模拟风增水、风速等核心变量,能够反映风暴潮的主要驱动力和响应特征(见表1)。物理交互项基于风暴潮动力机制设计,例如增水与风增水乘积项反映二者非线性相互作用,潮位与风速交互项体现天文潮与气象潮的耦合效应。引入平方项等非线性变换项,用以捕捉潜在的阈值效应和正反馈机制。风暴潮过程中,当风速超过临界值时,海气交换机制可能发生突变;类似地,当增水达到一定高度时,有效水深的改变会进一步影响后续能量

积累过程。物理比率特征(如风增水贡献比例、单位风增水所需风速),可表征变量间相对关系,具备更好的普适性和稳定性。

这种特征设计理念源于对风暴潮动力机制的物理理解:模式水动力过程参数化的不确定性,对增水误差有重要影响。通过构建物理意义明确的衍生特征,模型能够学习普适的风暴潮误差修正规律,实现对不同地理位置 ADCIRC 模拟结果的统一订正。该方法显著提升了模型泛化能力和实际应用价值,使其能够适应未参与训练的新增站点和未知风暴潮事件。

数据划分采用基于时间的交叉验证方法,分别选取 2024 年 9 月和 11 月部分站点数据作为测试集,其余数据作为训练集。这种划分方法确保训练集和测试集在时间上的独立性,更符合模型在实际应用中的场景。最终获得 1 377 个有效训练样本和 240 个测试样本,样本量满足机器学习模型训练的基本要求。

2.2 训练结果与实例测试

模型训练结果显示,基于 1 377 个样本的训练数据,随机森林模型展现出卓越的学习能力和泛化性能。训练集 R^2 达到 0.72, RMSE 为 16.69;测试集 R^2 为 0.65, RMSE 为 21.24。训练集与测试集性能差

表1 模型各特征类别、意义与单位
Tab.1 Model feature categories, meanings, and units

类别	特征名	意义	单位
基础物理量	天文潮位	潮汐引起的周期性水位	cm
	风强迫水位	引入风场后模式模拟的水位	cm
	风速	海表面 10 m 高度风速	m/s
	增水	风暴潮引发的水位变化大小	cm
物理交互项	增水×风速	增水与风速交互项	cm ² /s
	天文潮位×风速	天文潮位与风速交互项	cm ² /s
	风强迫×风速	风强迫水位与风速交互项	cm ² /s
	增水×天文潮位	增水与天文潮位交互项	cm ²
	单位风速增水	单位风速所产生的增水效应	s
	单位增水风速	单位增水所需风速影响	s ⁻¹
非线性变换项	增水平方项	增水非线性效应	cm ²
	风速平方项	风速非线性效应	m ² /s ²
	风强迫水位平方项	风强迫水位非线性效应	cm ²
	天文潮位平方项	天文潮位非线性效应	cm ²
物理比率特征	增水/天文潮	增水与天文潮位比	无量纲
	天文潮比例	天文潮位与风强迫水位比	无量纲
	增水比例	增水与风强迫水位比	无量纲
	风速/风强迫	风速与风强迫水位比	s ⁻¹

距较小(R^2 相差 0.068 7),表明模型结构设计合理,未出现明显过拟合现象。从误差分布来看,训练集和测试集的相关系数分别达到 0.86 和 0.81,表明模型不仅能够准确预测增水的幅值,更能捕捉其变化相位和趋势,这对风暴潮预警时效保障至关重要。

特征重要性分析结果(见图 3)可为理解影响风暴潮模拟误差的关键因素提供理论支撑。分析结果表明,风速相关特征(原始风速为 0.150 2 m/s、风速平方为 0.146 4 m²/s²)合计贡献率达 29.5%,与风应力驱动风暴潮理论高度吻合,证实了风场在风暴潮生成中的主导作用。特别值得注意的是风速平方项的贡献占比较高,反映了风应力与风速之间的非线性关系(风应力与风速的平方成正比),模型成功捕捉到了这一关键物理规律。

增水平方项的重要性为 0.117 7,反映了风暴潮在增长过程中存在潜在的正反馈机制。当增水达到一定阈值后,可能通过改变有效水深、影响波浪破碎和能量耗散等方式进一步加剧增水,准确捕捉

这种非线性特性对极端风暴潮预报尤为重要。增水×风速(重要性为 0.133 6)、单位增水风速(重要性为 0.047 2)等交互特征的重要性,揭示了多物理场耦合的复杂性,说明单一物理过程的线性叠加无法充分描述真实的风暴潮动力过程。天文潮特征重要性(0.015 8)相对较低,符合物理认知。研究时段内天文潮周期性变化相对稳定、可预测性强,易于模型拟合;而气象潮具有随机性和突发性,所需建模资源更多。这一发现为特征选择提供了重要指导,在保证模型性能的同时可以适当简化特征空间。

为验证模型订正效果,选取 2024 年 9 月和 11 月两次风暴潮过程开展实例测试。时间序列对比清晰展示了模型在不同条件下增水及误差的订正效果(见图 4)。9 月过程中,订正后曲线(红色)相较原始模拟结果(蓝色)更贴近实测值(绿色),特别是在增水峰值处(第 20~30 h)改进效果明显。模型既修正了幅值误差,还改善了相位特征,预测的峰值出




图3 训练集特征重要性排序

Fig.3 Feature importance ranking in the training dataset




图4 测试案例观测、模拟与订正结果时间序列

Fig.4 Time series of observed, simulated, and corrected results for the test cases

现时间更加准确。11月过程中,原始模拟存在显著系统性高估,经订正后幅值误差大幅减小,同时保持了时序变化趋势的一致性。

散点图从定量角度对比了订正前后的增水误差分布(见图5)。9月过程订正后,数据点更贴近1:1等

值线,离散度明显减小,整体改进率为11.65%;11月过程的改进更为显著,原本广泛离散分布的数据点向1:1线集中,系统性偏差基本消除,改进率达48.08%。

误差分布直方图从统计角度验证了模型的优化效果(见图6)。订正后两个过程的增水误差分布




图5 测试案例误差散点图

Fig.5 Scatter plots of errors for the test cases

均更集中、峰值更尖锐。9月过程的误差标准差从订正前的约14.60降低至约12.92,11月过程从约21.42显著降至约12.82,表明模型可有效减少模式的系统性偏差。

箱型图直观比较了订正前后的误差统计特征(见图7)。订正后两次过程的误差中位数均更接近零值,且四分位距(Interquartile range, IQR)显著减少。9月过程的IQR从约19.63降至约19.31,11月过程从约26.65大幅降至约16.27,异常值数量明显减少,体现了模型对极端误差的控制能力。

泰勒图综合评估了模型的统计性能(见图8)。订正后两次过程的标准差更接近参考状态(观测值)。9月过程的相关系数从约0.62提升至约0.70;11月过程相关系数略有回落(从约0.44变化至约0.42),但标准差改善幅度显著,证实模型在优化标准差方面优势明显。

3 分析和讨论

测试结果明确揭示了风速条件对ADCIRC模式模拟质量的决定性影响。9月过程中,在高速风条件下,原始模拟已具备较好的预测能力,这与强风条件下风应力成为明确主导驱动力密切相关。在台风“摩羯”影响期间,海面风场结构紧密、强度大,风应力输入的能量显著高于其他能量耗散过程,使得主要物理过程相对明确,数值模式能够较好地模拟这一主导机制。模型在此基础上的适度改进(改进率11.65%),体现了对高质量模拟结果的精细化优化能力。

相比之下,11月过程中,在低风速条件下原始模拟质量显著下降,最大增水平均相对误差约66.9%,这深刻反映了数值模式在弱风条件下对次网格过程和非线性相互作用等复杂机制的表征不




图6 测试案例误差分布直方图

Fig.6 Error distribution histograms for the test cases




图7 测试案例误差统计分析箱形图

Fig.7 Box plots of error statistics for the test cases

足。在冷空气影响期间,海面风场相对较弱且空间分布均匀,多种物理过程贡献相当,无明显主导机制。这种情况下,边界层过程、海气交换、波浪-环流相互作用等次网格尺度过程的影响更加显著,而传统数值模式对这些过程的参数化存在较大不确定性。模型在这种复杂条件下实现约48.08%的误差降幅,充分展现了机器学习对低风速复杂情景的特

殊处理能力,可通过数据驱动方式弥补物理模型的不足。

从技术层面看,模型的突出优势体现在误差收敛特性上。尽管两个过程中原始模拟质量差异显著(RMSE相差11.13),订正后误差水平却趋于接近(12.96、13.40)。这种误差标准化能力为业务预报结果的一致性提供了技术保障,表明模型学到了合




图8 测试案例泰勒图分析

Fig.8 Taylor diagram analysis for the test cases

理的风暴潮误差订正规律,而非单纯记忆特定模式。从机器学习角度分析,这种特性源于随机森林模型对复杂非线性关系的捕捉能力和对异常值的鲁棒性。

特征重要性分析进一步验证了模型的物理合理性。风速相关特征的主导地位与已有物理认知一致,证实模型习得规律与风暴潮生成基本原理相符。非线性项和交互项的重要性则揭示了传统线性订正方法的局限性,也说明了考虑过程非线性和多物理场耦合的必要性。特别值得注意的是,不同过程中特征重要性相对稳定,表明模型学习的订正规律具有较好的普适性,可为业务化应用的可靠性提供支持。

基于以上分析,建议构建条件自适应订正系统,基于风速等环境条件自动调整订正强度。具体可建立风速-订正强度关系函数,对高质量原始模拟采用轻度订正以保留其原有信息,对低质量模拟启动强化订正,最大程度改善模拟结果的可用性。同时建议搭建业务数据在线学习机制,通过增量学习方式持续优化模型性能,以适应气候变化背景下风暴潮特征的可能变化。

11月过程中出现了负的 R^2 值(见图5),从统计学角度看,这表示模式残差平方和大于仅使用观测均值作为预测值的总平方和;具体而言,低风速下风暴潮增水信号较弱,模式难以准确模拟实际水位的小幅度变化。经模型订正后, R^2 得到大幅提升,进

一步印证了本订正方法在低风速情景下的应用优势。然而,11月过程订正后 R^2 仍未转正(-0.11),也揭示了低风速情景下深层次的建模难点。从物理机制角度分析,原因主要包括:边界层过程中非局地湍流输送的次网格效应、海气交换过程阵发性引发的非线性响应、天气尺度与中小尺度系统间多尺度相互作用等未被充分表征的物理机制。此外,本研究训练数据仅包含两次风暴过程,当前模型对极端个例的处理能力仍有提升空间,需纳入更多样化训练数据并完善特征工程,进一步增强模型鲁棒性。

4 结论

本研究构建了基于随机森林的ADCIRC模式风暴潮数据订正方法,并对广东海域2024年两次风暴潮过程开展系统验证。主要结论如下:

①机器学习订正模型可显著提升ADCIRC模式的风暴潮模拟精度,平均改进率达29.87%。订正效果在不同风速条件下存在明显差异:高风速条件下改进率为11.65%,低风速条件下改进率达48.08%。这种差异化特征体现了机器学习订正方法与数值模式的互补性:在物理模型表现较好时实现精细化优化,在物理模型存在明显不足时实现有效修正。

②模型具备良好的泛化性能和物理一致性。

训练集与测试集性能相近(R^2 相差 0.068 7),表明模型未过度依赖训练数据的特定特征,具备较好的推广能力。特征重要性分布符合风应力驱动理论,非线性项和交互项的重要性揭示了风暴潮动力过程的复杂性。上述结果既验证了模型的物理合理性,也可数值模式参数化方案优化提供方向。

③研究明确了风速条件是决定数值模拟质量的关键因素。低风速情景下的模拟误差显著高于高风速情景,这一研究深化了对数值模式性能边界的认知。相应地,机器学习订正模型在弱风条件下表现出特殊应用价值,可为复杂天气条件下的风暴潮预报提供有效技术途径。

本研究仅基于 2024 年两次台风风暴潮过程进行方法验证,模型在不同年份、不同风暴类型下的性能,仍需更多样本数据进一步训练与验证。同时,考虑到 ERA5 数据集存在台风风速低估问题,未来需采用精度更高的风场资料开展模型训练和改进。

总之,机器学习与物理模型的融合给风暴潮预报带来了新的机遇。通过持续的方法创新和技术优化,有望构建更智能、精准、可靠的风暴潮预报系统,为沿海地区的可持续发展和防灾减灾提供更有力的科技支撑。本研究证实了机器学习在风暴潮数值预报订正中的有效性和实用性,可为提升沿海风暴潮预警能力提供新的技术途径。未来研究将聚焦于低风速情景的专项优化、多源数据的融合应用及业务系统的深度集成,进一步推动海洋气象预报的智能化发展。

参考文献:

- [1] 于福江,傅赐福,郭洪琳,等. 现代风暴潮预报技术及应用[M]. 北京: 科学出版社, 2020.
YU F J, FU C F, GUO H L, et al. Modern technologies and application in storm surge forecasting[M]. Beijing: Science Press, 2020.
- [2] 冯士筭. 风暴潮导论[M]. 北京: 科学出版社, 1982.
FENG S Z. Introduction to storm surge[M]. Beijing: Science Press, 1982.
- [3] 付翔,梁森栋,郭洪琳,等. 中国沿海 40 年台风风暴潮特征研究[J]. 海洋预报, 2023, 40(6): 1-11.
FU X, LIANG S D, GUO H L, et al. Characteristic analysis of tropical storm surges affecting the coastal area of China in the past 40 years[J]. Marine Forecasts, 2023, 40(6): 1-11.
- [4] 马永锋,祖子清,李涛,等. 风暴潮增水长期模拟结果的订正方法研究[J]. 海洋预报, 2015, 32(5): 35-44.
MA Y F, ZU Z Q, LI T, et al. Study of the correction method on long-term simulations of storm surge elevation[J]. Marine Forecasts, 2015, 32(5): 35-44.
- [5] 熊杰,傅赐福,于福江,等. 基于 ECMWF 细网格风场的台风“烟花”与飓风“艾达”风暴潮数值预报检验与分析[J]. 海洋预报, 2022, 39(3): 1-9.
XIONG J, FU C F, YU F J, et al. Verification and analysis of numerical forecast of typhoon "In-Fa" and hurricane "Ida" storm surge based on ECMWF fine grid wind field[J]. Marine Forecasts, 2022, 39(3): 1-9.
- [6] 侯琪,李晓敏,张杰,等. 基于随机森林的台风风暴潮强度估计方法[J]. 信息技术, 2024(9): 84-90.
HOU Q, LI X M, ZHANG J, et al. Typhoon storm surge intensity estimation method based on Random Forest[J]. Information Technology, 2024(9): 84-90.
- [7] 尤成,于福江,原野. 基于相空间重构的神经网络风暴潮增水预测方法[J]. 海洋预报, 2016, 33(1): 59-64.
YOU C, YU F J, YUAN Y. Storm surge prediction method of neural network based on phase space reconstruction[J]. Marine Forecasts, 2016, 33(1): 59-64.
- [8] 刘珍,莫冬雪,方泳,等. 基于神经网络的台风风暴潮区域预报方法研究: 以黄渤海为例[J]. 海洋与湖沼, 2025, 56(5): 1058-1072.
LIU Z, MO D X, FANG Y, et al. On regional forecasting method of typhoon storm surge based on neural network: a case study of the Yellow Sea and Bohai Sea[J]. Oceanologia et Limnologia Sinica, 2025, 56(5): 1058-1072.
- [9] 张娟,周水华,黄宝霞,等. 人工神经网络在台风风暴潮模拟中的解释应用[J]. 海洋预报, 2016, 33(2): 60-65.
ZHANG J, ZHOU S H, HUANG B X, et al. Interpretation of numerical storm surge model results using the artificial neural network[J]. Marine Forecasts, 2016, 33(2): 60-65.
- [10] LIU Y, ZHAO Q S, HU C C, et al. Prediction of storm surge water level based on machine learning methods[J]. Atmosphere, 2023, 14(10): 1568.
- [11] AYYAD M, HAJJ M R, MARSOOLI R. Machine learning-based assessment of storm surge in the New York metropolitan area[J]. Scientific Reports, 2022, 12(1): 19215.
- [12] CHEN K, KUANG C P, WANG L, et al. Storm surge prediction based on long short-term memory neural network in the East China Sea[J]. Applied Sciences, 2021, 12(1): 181.
- [13] DULLAART J C M, MUIS S, BLOEMENDAAL N, et al. Advancing global storm surge modelling using the new ERA5 climate reanalysis[J]. Climate Dynamics, 2020, 54(1-2): 1007-1021.
- [14] WESTERINK J J, LUETTICH R A, FEYEN J C, et al. A basin- to channel-scale unstructured grid hurricane storm surge model applied to southern Louisiana[J]. Monthly Weather Review, 2008, 136(3): 833-864.

[15] LUETTICH JR R A, WESTERINK J J, SCHEFFNER N W. ADCIRC: an advanced three-dimensional circulation model for shelves, coasts, and estuaries. Report 1. Theory and methodology of ADCIRC-2DDI and ADCIRC-3DL[R]. 1992.

[16] DIETRICH J C, ZIJLEMA M, WESTERINK J J, et al. Modeling hurricane waves and storm surge using integrally-coupled, scalable computations[J]. Coastal Engineering, 2011, 58(1): 45-65.

Machine learning-based correction and evaluation of storm surge simulation data for Guangdong coastal waters

YU Chongyang¹, ZHANG Lu²

(1. College of Oceanography, Hohai University, Nanjing 410073, China; 2. National Marine Environmental Forecasting Center, Beijing 100081, China)

Abstract: This study utilized the ERA5 reanalysis wind fields and sea level pressure data from the European Centre for Medium-Range Weather Forecasts (ECMWF) to drive the ADCIRC model, constructing an hourly storm surge dataset for two storm surge processes in Guangdong coastal waters in 2024. To correct the systematic errors in the storm surge simulations, by constructing a feature system comprising 17 physical features including simulated surge, tidal level, wind-induced surge, wind speed, and their derived interaction terms, a machine learning error correction model based on Random Forest regression with clear physical significance was established. Training results demonstrated the model's strong learning capability on 1 377 samples, with an R^2 of 0.71 and 0.65, an RMSE of 16.7 and 21.2, and correlation coefficients of 0.86 and 0.81 for the training and test sets, respectively. Case studies showed that the model achieved improvement rates of 11.65% for the high-wind-speed case in September 2024 and 48.08% for the low-wind-speed case in November 2024, with an average improvement rate of 29.87%. The research suggests that this machine learning correction method effectively reduces systematic errors in the ADCIRC model, particularly demonstrating stronger correction capability under low-wind-speed conditions.

Key words: Guangdong coastal waters; storm surge; numerical simulation; machine learning