

童宏福, 冯鑫, 刘家谦, 等. 基于前期海温波动与机器学习的复合干热灾害预报: 以珠江流域为例[J]. 水利水电技术(中英文), 2026, 57(8): 162-174. DOI: 10.13928/j.cnki.wrahe.2026.08.012

TONG Hongfu, FENG Xin, LIU Jiaqian, et al. Forecasting of compound dry-hot events based on preceding sea surface temperature patterns and machine learning: A case study of Pearl River Basin[J]. Water Resources and Hydropower Engineering, 2026, 57(8): 162-174. DOI: 10.13928/j.cnki.wrahe.2026.08.012

基于前期海温波动与机器学习的复合干热灾害预报：以珠江流域为例

童宏福¹, 冯鑫², 刘家谦², 李军², 吴旭树², 张大伟³

(1. 广东省水文局清远水文分局, 广东 清远 511599; 2. 华南理工大学土木与交通学院, 广东 广州 510640; 3. 广州珠科院工程勘察设计有限公司, 广东 广州 510610)

摘要:【目的】气候变化背景下复合干热灾害呈加剧趋势, 对社会与生态系统构成了严重威胁。为提升复合干热灾害的预警与防范能力, 亟须建立高精度复合干热事件预报模型。【方法】基于不同时期的海温构建前期海温波动模式(PSFP)作为预报因子, 采用 Loess 季节趋势分解方法进行数据处理, 结合支持向量机(SVM)、随机森林(RF)和极限学习机(ELM), 建立了具备确定、集合与概率预报的复合干热灾害预报模型(PSFP-SVM、PSFP-RF 和 PSFP-ELM)。以珠江流域为研究区, 选取 1989 年、1991 年、1999 年、2011 年夏季的典型复合干热事件进行模型检验。【结果】结果表明: 1 和 3 个月预见期下模型能有效预报珠江流域夏季复合干热事件时空分布特征, 其中 PSFP-ELM 效果最佳, 其 R^2 高于 0.5, 准确率高于 0.8, 预报结果与实测值高度一致, 且在三个月预见期下表现更优。PSFP 模型预报精度显著高于基于环流因子的传统预报模型, 效果提升可达十倍以上。【结论】研究成果可为干热灾害的风险预警和防灾减灾决策提供科学支撑。

关键词: 复合干热灾害; 预报; 机器学习; 前期海温波动; STL 分解; 珠江流域; 概率预报; 影响因素

DOI: 10.13928/j.cnki.wrahe.2026.08.012

开放科学(资源服务)标志码(OSID):

中图分类号: P429

文献标志码: A

文章编号: 1000-0860(2026)08-0162-13



Forecasting of compound dry-hot events based on preceding sea surface temperature patterns and machine learning: A case study of Pearl River Basin

TONG Hongfu¹, FENG Xin², LIU Jiaqian², LI Jun², WU Xushu², ZHANG Dawei³

(1. Qingyuan Hydrology Sub-bureau of Guangdong Province, Qingyuan 511599, Guangdong, China; 2. School of Civil Engineering and Transportation, South China University of Technology, Guangzhou 510640, Guangdong, China;

收稿日期: 2025-08-09; 修回日期: 2025-10-20; 录用日期: 2025-10-28; 网络出版日期: 2025-11-05

基金项目: 国家自然科学基金项目(52479015); 广东省自然科学基金项目(2023A1515030191); 华南理工大学中央高校基本科研业务费杰出青年项目(2024ZYGXZR084)

作者简介: 童宏福(1978—), 男, 高级工程师, 学士, 主要从事水情预报、水文与水资源分析计算工作。E-mail: tonghongfu_gdqysw@163.com

通信作者: 张大伟(1986—), 男, 高级工程师, 硕士, 主要从事水利规划和水旱灾害防御。E-mail: waterscholar@163.com

©Editorial Department of Water Resources and Hydropower Engineering. This is an open access article under the CC BY-NC-ND license.

3. Guangzhou PRHRI Engineering Survey and Design Co., Ltd., Guangzhou 510610, Guangdong, China)

Abstract: [Objective] In the context of climate change, compound dry-hot events (CDHEs) have shown an increasing trend in both frequency and intensity, posing severe threats to social and ecological systems. To enhance the early warning and prevention capability for CDHEs, it is imperative to establish a high-precision forecasting model. [Methods] Preceding sea surface temperature fluctuation patterns (PSFP) were constructed as predictors based on SST variations during different periods. The data were processed using the Loess seasonal-trend decomposition method. Three machine learning models—support vector machine (SVM), random forest (RF), and extreme learning machine (ELM)—were employed to develop deterministic, ensemble, and probabilistic forecasting models (PSFP-SVM, PSFP-RF, and PSFP-ELM) for CDHEs. Taking the Pearl River Basin as the study area, four representative summer CDHEs in 1989, 1991, 1999, and 2011 were selected for model validation. [Results] The result showed that the models could effectively predict the spatiotemporal distribution characteristics of summer CDHEs in the Pearl River Basin with 1-and 3-month lead time. Among them, the PSFP-ELM model performed best, achieving an R^2 higher than 0.5 and an accuracy exceeding 0.8. Its forecast result showed strong agreement with observations and superior performance at the 3-month lead time. The forecasting accuracy of the PSFP-based models was significantly higher than that of traditional circulation factors-based models, with performance improvements exceeding tenfold. [Conclusion] The findings provide a scientific basis for risk early warning and decision-making of disaster prevention and mitigation regarding CDHEs.

Keywords: compound dry-hot events; forecasting; machine learning; preceding sea surface temperature fluctuation; STL decomposition; Pearl River Basin; probabilistic forecasting; influencing factors

0 引言

IPCC 第六次评估报告指出,随着全球气候持续变暖,全球干旱、高温等极端气候事件的空间范围、频率及强度均呈显著上升趋势^[1-2]。相较于单一灾害,干旱与高温的时空耦合效应会进一步引发破坏性更强的复合干热事件(Compound Dry-Hot Event, CDHE)^[3]。以2003年欧洲的CDHE为例,事件导致约7万人死亡,造成经济损失高达79亿美元;2022年我国长江流域发生了严重的CDHE,其覆盖范围达8 000 km²,对水资源、生态环境和农业生产造成了严重冲击^[3-4]。现有文献表明,1951至2012年间,全球陆地CDHE的频率、严重程度、持续时间和规模都随时间显著增长^[5]。频发的CDHE对全球农业、生态、水资源及公共健康造成多维度危害,且预计未来将随着气候变暖持续加剧^[6]。我国水旱灾害防御体系的完善,需坚持“预字当先、以防为主”,凸显了当下加强水旱灾害预防技术研究的紧迫性^[7-8]。因此,探究CDHE高效预报技术,对于复合灾害的防灾减灾工作具有重要现实意义。

学者们对CDHE的发生机制进行了全面的探究,发现CDHE通常与海表温度(Sea Surface Temperature, SST)驱动的大尺度大气环流模式持续异常相关^[9-10]。太平洋和大西洋SST异常通过调节大气环流模式和位势高度场调控暖湿空气和降水的空间分布,进而影响CDHE的频率和强度^[11]。FENG等^[12]进一步的研究

发现ENSO会导致暖季CDHE发生风险提高约60%。因此,海温异常是分析和预测区域CDHE演变特征的重要因素。尽管近年来CDHE的演变特征分析与致灾机制研究已取得显著进展,但有关其预报方法的研究却相对较少^[13]。HAO等^[14]基于ENSO与CDHE的显著相关性,建立了一种用于预报非洲南部夏季CDHE强度的联合统计模型,并证明了其良好的预报性能。HAO等^[15]基于NINO3.4区指数,采用有序回归模型对东北夏季不同类别的CDHEs进行概率预测,该方法在东北大部分地区有着较高的预报精度,尤其是在8月表现突出。但此类预报方法往往仅依赖于一种或数种特定的海温环流因子,而未能充分考虑其他区域海温与地区CDHE间的潜在联系,从而影响预报精度。因此发展适用于多地区、多气候条件的CDHE通用预报模型仍面临着严峻挑战。

动力模型和统计模型是当前水文气象预报的两大主流方法^[16]。动力模型物理机制明确,结果可靠,其通过数值模拟,全面考虑大气、海洋、陆地等系统的物理过程,能够反映气候系统内部的耦合反馈机制,因此在理论研究和气候变化情景分析中具有重要作用。目前如全球气候模型等动力学方法已用于预测未来气候变化情景下CDHE的时空变化^[17]。但同时此类模型依赖高性能计算资源,模型参数设置复杂,且对初始和边界条件敏感,导致在区域尺度应用时面临较大挑战,特别是在数据匮乏或技术条件有限的地区,动力模型的实际推广受到较大限制。相比之下,

统计模型凭借算法简约、性能可靠的优点,成为具有大规模应用潜力的重要预报工具^[18]。统计模型主要通过分析历史气象数据与灾害事件间的统计规律,建立输入因子与预报对象之间的经验关系,具有实现简单、计算效率高、易于大规模推广的优势。统计模型在实际预报业务中广泛应用,能够快速响应和适应不同区域、不同气候背景的需求。但现有统计模型大多基于线性关系假设,难以捕捉气象数据中复杂的非线性特征。近年来,机器学习算法的引入有效弥补了这一局限。机器学习方法能够自动挖掘气象数据中的潜在规律,建模过程中无需预设复杂的物理机制,且对数据的非线性分布具有良好适应性,因此在极端气候事件预报领域展现出广阔应用前景^[19]。例如,BELAYNEH等^[20]利用SVR和神经网络预测标准化降雨指数。LI等^[21]利用SST数据构建支持向量机(SVM)、随机森林(RF)和极限学习机(ELM)模型以预测气象干旱。QIN等^[22]基于轻量梯度提升机(LightGBM),RF和极端梯度提升(XGBoost)捕捉东北地区干旱时空变化模式并进行预测。在极端气象事件预报研究中,相较于其他如KNN、XGBoost等模型,SVM、RF和ELM三种模型更受青睐^[23-24]。SVM模型在处理高维、小样本、非线性问题方面表现优异,能够有效应对气象数据的复杂分布特性;RF模型作为集成学习方法,具备较强的鲁棒性和抗过拟合能力,适合捕捉气象因子间的非线性关系及特征重要性;ELM模型则以极快的训练速度和良好的泛化性能见长,能在大规模数据预报任务中实现高效计算。SVM、RF和ELM分别在非线性建模、特征集成与高效计算等方面具有明显优势,有助于充分挖掘气象水文数据复杂的信息特征,并已广泛应用于如极端洪涝与降雨预测等任务中^[21]。

尽管机器学习在统计预报中展现出巨大潜力,当前CDHE的统计模型预报研究仍存在明显局限。针对气象序列非平稳性特征的预处理技术应用不足,如小波变换和基于Loess的季节趋势分解(STL)等信号分解技术在CDHE预报中的应用相对缺乏^[19,25]。若未对非平稳序列数据进行预处理,原始数据的内在属性会因将预报对象/预报因子作为一个整体建模而被覆盖,从而降低预报精度^[20]。此外,预报结果的不确定性量化方法存在局限。集合和概率预报可量化极端事件发生的不确定性,为风险决策提供科学依据,而鲜有CDHE预报研究能有效整合确定性、集合和概率预报方法。发展融合多种数据处理方法与预报结果的技术体系,对于提升CDHE预报能力、深化对

其发生发展机理的认识以及优化灾害风险防控策略,均具有关键意义。

为进一步提升CDHE的预报效率与精度,本文提出了一种新型CDHE预报模型。该模型融合集合预报、概率预报及确定预报方法,以前期海温波动模式(Preceding SST Fluctuation Pattern, PSFP)为预报因子,结合基于Loess的季节趋势分解方法,以及随机森林(RF)、极限学习机(ELM)和支持向量机(SVM)三种机器学习算法,实现网格尺度的CDHE高效预报。以珠江流域为研究区,选取1989年、1991年、1999年、2011年夏季的典型灾害事件进行模型的预报应用与综合性能评估,以期CDHE风险管理提供科学工具。

1 数据与方法

1.1 研究区概况与数据

珠江流域作为中国第三大河流域,由西江、北江、东江及珠江三角洲诸河等四大水系构成,涵盖广东、湖南等八省,总面积约45.4万km²,水系纵横、地形多样。珠江流域地处热带-亚热带季风气候区,降水时空分布差异显著,暴雨、洪涝与干旱、高温等极端气象灾害频发。流域内人口稠密,经济活动活跃,是中国重要的经济带和淡水资源供给区;珠江三角洲更是全球制造业和出口贸易的重要枢纽,对区域水资源及生态安全要求极高。近年来,受全球气候变暖及区域人类活动影响,珠江流域极端气候事件呈现多发态势。流域干旱与高温复合灾害频率与强度不断攀升,导致水库蓄水能力下降、水资源短缺加剧,影响了农业灌溉、城市供水、生态健康及能源安全。同时,流域生态系统多样性丰富但也极易受气候异常扰动,水环境承载力面临挑战。社会经济高度敏感,极端气候事件对人口健康、工业生产及区域可持续发展构成直接威胁。基于珠江流域典型的气候矛盾性与社会经济高敏感性,选定该区域开展CDHE预报模型的适用性评估,具有重要理论和应用价值,其流域地理概况及空间分布如图1所示。

本文气候数据采用英国气候中心提供的1901—2018年月尺度数据集CRU TS v. 4.03(<http://www.cru.uea.ac.uk/data>),其原始空间分辨率为0.5°×0.5°。STI序列基于CRU数据集的温度序列计算,时间尺度为3个月,并采用正态分布进行拟合,空间分辨率为0.5°×0.5°。SPEI序列则选自西班牙高等科学研究委员会CSIC公开数据库(<https://digital.csic.es/handle/10261/268088>),时间尺度同为3个月,采用Logistic分布拟合,空间分辨率为0.5°×0.5°,其中潜




图 1 珠江流域地理概况

Fig. 1 Geographical overview of Pearl River Basin

在蒸散发(PET)采用 Penman-Monteith 方法进行估算。利用双线性插值法对上述数据集进行重采样至 $1^{\circ} \times 1^{\circ}$, 基于该分辨率构建预报模型。SST 数据采用美国国家海洋和大气管理局的 COBE-SST 数据集 (<https://www.psl.noaa.gov/data/gridded/>), 时间跨度为 1901—2018 年, 空间分辨率为 $1^{\circ} \times 1^{\circ}$ 。26 个海洋环流指数数据来自中国气象数据网 CMDN 数据集 (<https://cmdp.ncc-cma.net/cn/monitoring.htm#enso>), 均已完成去趋势与标准化等预处理, 具体名称如表 1 所列。

表 1 26 项海洋环流因子

Table 1 26 ocean circulation factors

26 项海洋环流因子	
NINO 1+2 SSTA 指数	印度洋暖池强度指数
NINO 3 SSTA 指数	西太平洋暖池面积指数
NINO 4 SSTA 指数	西太平洋暖池强度指数
NINO 3.4 SSTA 指数	大西洋年代际振荡指数
NINO W SSTA 指数	亲潮区海表温度指数
NINO C SSTA 指数	西风漂流区海表温度指数
NINO A SSTA 指数	黑潮区海表温度指数
NINO B SSTA 指数	ENSO Modoki 指数
NINO Z SSTA 指数	暖池 ENSO 指数
热带北大西洋海表温度指数	冷舌 ENSO 指数
热带南大西洋海表温度指数	印度洋盆地指数
西半球暖池指数	热带印度洋偶极子指数
印度洋暖池面积指数	南印度洋偶极子指数

1.2 复合干热指数

多元随机变量的联合概率是评估 CDHE 的有效方法^[26-27]。HAO 等^[14]提出了标准化复合事件指标 (Standardized Compound Event Indicator, *SCEI*), 通过标准化干旱和高温指数的联合概率来量化 CDHE 的严重程度, 该指数在监测和刻画全球 CDHE 特征方面表现良好。原 *SCEI* 计算公式采用标准化降水指数 *SPI* 和标准化温度指数 *STI* 作边际概率分布, 但考虑到 *SPI* 仅基于降水数据, 未涵盖与干旱相关的其他气候因子(如温度、潜在蒸散发), 本文选用 *SCEI* 为衡量 CDHE 程度的指标, 由标准化降水蒸散发指数 (*SPEI*) 和标准化温度指数 (*STI*) 二者通过 Copula 联合分布函数构建。根据已有研究, 通过 AIC、BIC、KS 检验后选择了 Frank Copula 以计算联合分布概率, 并采用极大似然估计求解 Copula 参数^[26]。设有 *SPEI* (*X*) 和 *STI* (*Y*), CDHE 的联合概率可表示为

$$p = P(X \leq x, Y \geq y) = u - c(u, v) \quad (1)$$

式中, *u* 为 *X* 的边缘分布; *c*(*u*, *v*) 为联合分布。通过拟合分布 *F*, 将联合概率 *p* 转化为均匀分布, 再将其标准化, 以作为表征 CDHE 的指标。将序列 *p* 通过 Copula 函数拟合后转换为标准化单位, 则 *SCEI* 可通过联合累积概率(*p*)的倒数来计算, 具体为

$$SCEI = \varphi^{-1} \{ F[P(X \leq x, Y \geq y)] \} \quad (2)$$

式中, φ 为标准正态分布函数, 该分布通过 R 语言 “bestNormalize” 包的最佳归一化变换计算。基于 *SCEI* 的计算结果将 CDHE 的严重程度划分为 4 类, 如表 2 所列。

表 2 基于 *SCEI* 的复合高温干旱事件分类
Table 2 Classification of CDHE based on *SCEI*

CDHE 严重程度	数值区间
轻度	$-1.3 < SCEI \leq -0.8$
中度	$-1.6 < SCEI \leq -1.3$
重度	$-2.0 < SCEI \leq -1.6$
极端	$SCEI \leq -2.0$

1.3 前期海温波动模式

不同时期或区域之间的海温波动引起季节性气候变化, 区域水文气象变化可能与不同时期或区域之间海温的叠加或相减有密切关系^[28]。鉴于利用提前数月的气候信号有助于规避因滞后时间过长在复杂气候情景下带来的预报不确定性, 本文以 1~3 个月为预见期构建前期海温波动模式 PSFP, 具体定义如下。

类型 I 包含前期 1 个月海温信号为

$$PSFP_1 = SST_1 \tag{3}$$

类型 II 包含前期 2 个月海温信号为

$$\begin{cases} PSFP_2 = SST_1 + SST_2 \\ PSFP_3 = SST_1 - SST_2 \\ PSFP_4 = SST_1 - SST_3 \\ PSFP_5 = SST_1 + SST_3 \end{cases} \tag{4}$$

类型 III 包含前期 3 个月海温信号为

$$\begin{cases} PSFP_6 = SST_1 + SST_2 + SST_3 \\ PSFP_7 = SST_1 - SST_2 - SST_3 \\ PSFP_8 = SST_1 + SST_2 - SST_3 \\ PSFP_9 = SST_1 - SST_2 - SST_3 \end{cases} \tag{5}$$

式中, SST_1 、 SST_2 和 SST_3 分别为前期 1~3 个月的海温。

1.4 模型构建与性能评估

1.4.1 预报因子筛选与数据分解

考虑到非平稳序列预测效果的局限性^[20], 采用基于 Loess 的季节趋势分解方法 (Seasonal-Trend Decomposition Procedure Based on Loess, STL)。STL 分解的核心是具有迭代结构的局部加权回归 (LOESS), 是一种灵活的非参数回归方法, 其通过对时序数据点进行多次加权回归拟合, 连接各局部回归线形成平滑曲线, 进而揭示序列的整体趋势^[19]。此方法因其对数据局部特征的敏感性和适应性, 适用于提取复杂序列中的非线性关系, 并可分离出稳健的分量子序

列^[29]。利用 STL 将 *PSFP* (预报因子) 和 *SCEI* (预报对象) 分解为三个子序列: 趋势项、季节项和残差项, 对每个分解分量分别建立预报模型, 最终将预测结果叠加得到预报结果。STL 分解基于 R 语言 stl 程序包运行。其窗口参数 s. window 选用程序包中的 “periodic”, 周期参数设置为 12 (对应月度数据), 以反映海温序列的稳定季节性规律, t. window 设置为 NULL, robust 设置为 FALSE, 其他参数均采用默认设置, 由程序自动确定。STL 分解仅在训练窗口上进行参数拟合与分解, 分解所得季节性与趋势分量应用于训练集和验证集, 以保证评估过程中的数据独立性。

为提高预报精度与模型的可解释性, 需预先筛选高相关性的预报因子^[14]。相关系数分析是筛选潜在预报因子的常用方法^[30]。鉴于本模型采用 STL 分解和时间窗口移动处理长序列, 选用非线性方法将显著增加计算成本, 故采用相关系数法筛选与 CDHE 相关程度较大的海温格点 ($p < 0.05$), 提取该海洋区域 PSFP 作为预报因子。具体步骤为: 计算每个窗口下子预报因子和预报对象的相关关系。对相关性显著 ($p < 0.05$) 的网格点, 以其为起点遍历相邻网格, 将符合条件的网格数据归入当前预报因子, 直至没有网格符合要求为止, 最终提取该区域 PSFP 作为预报因子。为预防模型过拟合, 仅选取面积大于 $5 \times 10^6 \text{ km}^2$ 的预报因子区块。

1.4.2 机器学习模型

基于支持向量机 (SVM)、随机森林 (RF) 和极限学习机 (ELM) 三种机器学习模型捕捉预报因子和预报对象之间的非线性关系。SVM 是一种基于统计学习理论的监督学习算法, 兼具分类与回归功能。其核心思想是通过在特征空间中构建最优超平面, 实现样本的最大间隔分离, 从而提升泛化能力。RF 是集成学习方法的代表, 主要由多个决策树组成。RF 利用自助法 (Bootstrap) 从原始数据中随机抽取样本, 生成多个训练子集, 每个子集用于训练一棵回归树或分类树, 所有树的预测结果通过集成策略 (投票或平均) 进行汇总, 从而增强模型的稳定性和泛化能力。ELM 是一种单隐层前馈神经网络, 其结构简洁, 计算高效。其在训练过程中对输入层到隐层的权重和偏置进行随机初始化, 无需迭代优化。隐层输出与目标值之间的参数通过 Moore-Penrose 广义逆直接求解, 极大提升了训练速度。由于无需复杂的梯度下降过程, ELM 避免了传统神经网络中的收敛缓慢和局部极值问题, 适用于大规模数据快速建模。

采用上述三种机器学习模型分别对 STL 分解得到的分量子序列构建滑动窗口预报模型, 记为 PSFP-RF、PSFP-SVM 和 PSFP-ELM。在气象预报中, 30 a 周期被视为具有相对代表性和稳定气候模式的时间跨度^[31], 故选择 30 a 为滑动窗口 (1901—1988, ..., 1930—2017) 进行模型训练, 则对应共有 30 组验证预报输出 (1989—2018)。各分解分量预测结果由预测输出相加集成, 九种 PSFP 的预报结果构成集合预报 (Ensemble Forecast), 概率预报 (Probabilistic Forecast) 与确定预报 (Deterministic Forecast)。其中, 概率预报基于贝叶斯模型平均法 (Bayesian Model Averaging, BMA), 该方法基于最大似然法估算各子模型的动态权重, 实现基于概率框架的各分量加权平均融合^[32]。为论证本文预报模型的优势, 另外采用 26 项海洋环流指数作为预报因子分别构建多元线性回归 (MLR)、RF 和 XGBoost 模型进行预报效果对比。

1.4.3 精度评价

采用布莱尔分数 (Brier Score, BS) 和布莱尔技能分数 (Brier Skill Score, BSS) 进行集合预报与概率预

报评估。 BS 越接近于 0 表示预报越精确; BSS 为正表示预报效果较好。确定性预报评估基于归一化均方根误差 ($nRMSE$) 与列联表法进行。当 $nRMSE$ 低于 10% 则认为模型性能极佳; 高于 10% 但低于 20.0% 为良好; 高于 20% 但低于 30 % 为一般; 高于 30% 则为较差^[33]。根据列联表法可得出准确率 (AC)、检测率 (POD)、误报率 (FAR)、偏差分数 ($BIAS$) 和公正预报分数 (ETS)。 AC 、 POD 、 $BIAS$ 和 ETS 以 1 为最佳预报效果, FAR 以 0 为最佳^[34]。此外, 本文选取了 1989 年、1991 年、1999 年和 2011 年夏季典型 CDHE 的实测数据, 对模型结果进行实用性检验。本文技术路线如图 2 所示。

2 结果与讨论

2.1 集合预报与概率预报效果评价

构建 PSFP-RF、PSFP-SVM 与 PSFP-ELM 三种模型, 对 1989—2018 年珠江流域 $SCEI$ 进行 1 个月与 3 个月预见期下的 CDHE 预报, 并基于 BS 和 BSS 评估集合预报性能, 结果如图 3 所示。可知, 概率预报




图 2 CDHE 预报流程框架

Fig. 2 Framework of CDHE forecasting process




图3 珠江流域 SCEI 集合预报与概率预报效果评价

Fig. 3 Evaluation of ensemble and probabilistic forecasting results of SCEI in Pearl River Basin

与集合预报在性能上接近。在 1 个月预见期下, PSFP-ELM 表现最优, 其 BS 约为 0.14, BSS 约为 0.4; 而 PSFP-RF 和 PSFP-SVM 的 BS 则介于 0.18~0.27, BSS 低于 0.1。3 个月预见期下也呈现出相似结果, PSFP-ELM 的 BS 略有上升但仍低于 0.17, BSS 依然稳定在约 0.40, PSFP-RF 和 PSFP-SVM 的性能有所提高, BS 介于 0.18~0.3, BSS 保持在 0.1 上下, 但劣于 PSFP-ELM。 BS 与 BSS 结果经检验具有统计意义, 但鉴于篇幅及展示的简洁性, 置信区间和可靠度图未详细列出。

2.2 确定预报效果评价

基于 1989—2018 年的确定预报结果, 根据 $nRMSE$ 、 AC 、 POD 、 FAR 、 $BIAS$ 和 ETS 对 3 种模型进行深入评估, 如图 4 所示。其中, PSFP-ELM 的 $nRMSE$ 范围为 0.11~0.16, 且集中于 0.13 上下, 显著优于 PSFP-RF 和 PSFP-SVM ($nRMSE$ 为 0.15~0.22)。PSFP-ELM 的 AC 高于 0.8, POD 超过 0.6, FAR 低于 0.3, 显示出较强的识别能力与较低的误报倾向; 而 PSFP-RF 和 PSFP-SVM 的 AC 介于 0.55~0.75, POD 普遍低于 0.4, FAR 则超过 0.3。PSFP-ELM 的 $BIAS$ 分数介于 0.7~1.1 之间, 预报偏差较小, 而其他两种模型的 $BIAS$ 均低于 0.6, 倾向于低估 CDHE。PSFP-ELM 的 ETS 范围在 0.32~0.48, 显著优于随机预报, 而 PSFP-RF 和 PSFP-SVM 的 ETS

较低, 仅为 0.08~0.2。3 个月预见期下, PSFP-ELM 的 $nRMSE$ 较低, 集中在 0.15 之下, AC 高于 0.75, POD 高于 0.6, FAR 低于 0.3, $BIAS$ 范围为 0.8~1.1, ETS 范围为 0.3~0.5; 而 PSFP-RF 和 PSFP-SVM 的 $nRMSE$ 范围为 0.15~0.22, AC 则大多低于 0.75, POD 低于 0.5, FAR 高于 0.2, 集中于 0.3, $BIAS$ 范围为 0.2~0.6, ETS 范围为 0~0.2。

采用 26 种海洋因子构建 MLR、RF 和 XGBoost 传统 CDHE 预报模型, 并与 PSFP 预报模型进行精度对比分析, 如图 5 所示。其中, PSFP-ELM 的 R^2 最高, 普遍超过 0.5, PSFP-RF 和 PSFP-SVM 的 R^2 则在 0.2 上下波动。MLR 的 R^2 小于 0.02, RF 和 XGBoost 的 R^2 大多小于 0.01, 在 1 个月和 3 个月预见期下均明显劣于三种基于 PSFP 构建的预报模型。因此, 本文构建的新预报模型优于传统模型, 且 ELM-PSFP 表现最佳。

2.3 典型 CDHE 演变过程预报效果检验

前述证明 PSFP-ELM 具有最优预报效果, 故选取该模型进行典型 CDHE 事件预报效果评价。选取该流域 1989 年、1991 年、1999 年和 2011 年夏季的典型 CDHE 事件, 分别对模型的概率预报、确定预报与实测数据进行对比分析, 如图 6 所示。1989 年灾害事件中, 4 月流域东部出现 CDHE, 6—7 月西部地区 CDHE 加剧, 而东部则逐步减轻至消退。1991 年





图4 珠江流域三种预报模型的六项性能评估指标

Fig. 4 Six performance evaluation indicators of three forecasting models in Pearl River Basin

灾害事件中, 5—7月极端 CDHE 覆盖了大部分流域, 并随时间由南向北逐渐缓解, 至8月南部 CDHE 基本消退。1999年灾害事件中, 5月大部分地区出现了严重 CDHE, 6月略有缓解, 7—8月 CDHE 再次大范围蔓延并加剧, 尤以东部地区最为严重。2011年灾害事件中, 4月全流域均受严重影响, 北部尤甚, 5月 CDHE 重心转移至东部, 6—7月间东部逐渐缓解, 重心再次回归中部。此外, 1个月与3个月预见期的预报结果在空间演变趋势上与实测结果高度一致, 证明 PSFP-ELM 模型在预报该地区 CDHE 时空变化方面表现出良好的性能, 可有效预测 CDHE 的发生、发展与消退过程。

2.4 讨论

2.4.1 PSFP 对 CDHE 的影响机制

PSFP 作为表征海表温度在短期内快速变化的指标, 其本质反映的是海-气界面热通量的剧烈变化, 这种变化通过调节大气环流结构、水汽输送及大气热力稳定性, 主导了珠江流域 CDHE 的发生、发展与消退过程。WU 等^[28]的研究表明, 海温波动异常区域与 500 mb 位势高度异常区域存在大范围重叠, 二者在一定程度上相关。PSFP 异常的快速变化构成了对低层大气的加热或冷却源, 进而影响流域上空气流的分布。这种位于热带的异常热源能够激发准定常的遥相关波列, 该波列向中高纬度传播并影响沿途的大气环流系统^[35]。例如当特定 PSFP 表现为赤道中东




图 5 基于 PSFP 的预报模型与基于 26 海洋环流指数的预报模型精度比较

Fig. 5 Comparison of forecasting accuracies between PSFP-based models and 26 oceanic circulation factors-based models

太平洋海温快速上升时, 会激发一个异常上升运动气流, 并通过大气桥向东扩散能量, 最终可导致副热带高压异常增强并控制珠江流域, 从而加剧该地区下沉气流, 使大气层结更为稳定, 对流活动受抑, 地表温度升高, 空气相对湿度下降, 为 CDHE 的形成提供有利条件。此外珠江流域附近海域 PSFP 异常导致的反气旋环流可减少来自南海等区域的水汽输送, 进一步降低流域的大气湿度, 加剧高温背景下的干旱效应。同时大气层结稳定度增强 (如逆温层加厚) 使地表热量难以通过对流释放, 增加高温与干旱叠加的风险^[36]。珠江流域作为季风气候影响显著的区域, 其大气环流结构易受海温异常驱动的遥相关机制影响。PSFP 不仅作用于局地环流, 还通过类 ENSO 等遥相关过程调整远距离大气环流格局, 导致流域内 CDHE

的强度呈现动态变化并发生空间转移。如赤道太平洋及印度洋海温异常可通过影响风场结构和涡度分布, 激发西太平洋副热带高压的反气旋性异常和偏西偏强, 具体机制包括 El Niño 及其衰减过程引发西风异常和能量积累, 以及印度洋“电容器效应”在后期继续维持反气旋环流异常, 从而增强区域高温事件的发生与持续性^[37]。进一步研究指出, 赤道太平洋东部和印度洋整体主导影响珠江流域上中游的干旱形成, 而赤道东太平洋和南太平洋地区则主要影响流域下游的干旱过程^[16]。因此 PSFP 通过激发从源海区到目标区的遥相关波列, 在特定时段内重塑了珠江流域上空的环流格局和水汽输送通道, 并改变了局地大气的热力结构, 这一系列级联效应共同决定了 CDHE 的最终时空分布与强度。





图6 珠江流域典型CDHE时空演变过程预报效果评价

Fig. 6 Evaluation of forecasting performance of spatiotemporal evolution of typical CDHE in Pearl River Basin

2.4.2 CDHE 预报模型的潜在应用价值

本文提出的 CDHE 预报模型可为农业防灾和干旱应急调度提供科学理论依据。在珠江流域旱季来临前, 模型可通过预测特定预见期内 CDHE 的发生与消退概率, 实现对潜在极端灾害的提前预警, 指导地方部门合理调整水库蓄水策略和灌溉规划, 针对 CDHE 最严重时段实施精准防护, 降低因突发干旱造成的粮食减产和用水短缺风险, 并避免因过度蓄水导致的水资源浪费。模型预警结果亦可作为制定抗旱预案的重要参考。不同区域预报中 CDHE 严重程度及其空间分布差异, 有助于相关部门开展灾害风险分区管理, 针对流域内高风险地区提前制定调水和限水等应急措施, 提升灾害响应的精准性。此外, 模型还可用于优化种植结构, 根据灾害风险评估结果选择抗旱性强的作物品种或调整耕作计划, 从而降低灾害损失风险。

2.4.3 展望

尽管本文提出的方法在 CDHE 预报方面展现出良好性能, 但仍存在若干局限性。首先, 预报模型仅考虑了海表温度的变化影响, 而未引入大气指标与地表指标(如植被覆盖与人类活动)等相关信息, 较难反映大气-海洋-陆面交互耦合过程, 同时由于篇幅和数据处理复杂性, 相关合成及遥相关路径的量化分析未在本文详述; 其次, 尽管未涉及复杂的气象动力学机制计算, 本文提出的预报模型依赖于大范围的海表温度数据与再分析数据, 在实际应用中仍可能带来较大的计算负担与一定的计算误差。本模型构建过程步骤较为繁杂, 并且多次进行的序列分解与合成可能会导致分量间的信号泄露与误差的累积; 另外, 在基础设施建设薄弱、算力资源有限的欠发达地区, 大范围海温数据的提取与模型训练面临较大技术挑战, 可能难以满足高时效性和高精度的预报需求, 实际应用中需在预报结果的时效性与精度之间做出权衡。本研究选取了四种代表性年份的夏季 CDHE 事件进行分析, 目的是突出不同气候背景下的主要特征, 但由于数据和分析篇幅限制, 未能涵盖所有年份, 可能存在样本选择偏倚的局限。后续研究可从以下几个方面展开: 一是结合 SHAP (Shapley Additive Explanations)、LIME (Local Interpretable Model-agnostic Explanations) 等可解释性技术与水汽通量、位势高度等数据, 定量分析 PSFP 与其影响区域 CDHE 间的遥相关等潜在物理机制, 深入揭示影响当地 CDHE 的关键驱动海温网格; 二是引入气象、大气环流、地表过程等多源异构数据, 构建多源耦合的

复合灾害预报模型, 以提升模型对复杂灾害过程的刻画能力并降低数据导致的不确定性; 三是针对算力受限和数据稀缺的地区, 对计算流程进行简化以降低模型复杂程度, 提升其通用性与时效性。

3 结论

本研究构建了以 SCEI 为表征指标、PSFP 为预报因子的 CDHE 预报框架, 并以珠江流域为例进行应用评估, 结果表明: (1) 相较于 PSFP-RF 和 PSFP-SVR 模型, 1 个月和 3 个月预见期下 PSFP-ELM 模型更优, 其 R^2 整体高于 0.5, $nRMSE$ 约为 0.16, 对 CDHE 的检出率高于 0.6, 准确率高于 0.8, 同时误报率低于 0.3; (2) 模型在较长预见期下表现出更高的可靠性, 对于概率预报、集合预报与确定性预报 3 个月预见期的整体精度均略优于 1 个月预见期; (3) 预报模型在 1 个月和 3 个月预见期下的预报结果与观测值高度吻合, 可准确捕捉珠江流域夏季的 CDHE 时空演变模式; (4) 与基于环流因子的传统预报模型相比, 基于 PSFP 的预报模型精度更高, 其 R^2 可达前者的十倍以上, 具有更好的实际应用价值。本文所提出的模型为珠江流域提供了一个有效的 CDHE 预报方案, 同时可以推广至其他流域, 协助水资源综合管理和流域极端灾害预防工作。

参考文献 (References):

[1] 熊少堂, 赵铜铁钢, 郭成超, 等. 我国各大流域复合高温干旱事件变化趋势与归因分析[J]. 中国科学: 地球科学, 2024, 54 (1): 83-96.

XIONG Shaotang, ZHAO Tonggangtie, GUO Chengchao et al. Evaluation and attribution of trends in compound dry-hot events for major river basins in China[J]. Scientia Sinica (Terrae), 2024, 54 (1): 83-96.

[2] WU X Y, HAO Z C, TANG Q H, et al. Projected increase in compound dry and hot events over global land areas[J]. International Journal of Climatology, 2021, 41 (1): 393-403.

[3] GUO J, WANG F, WEN Y, et al. Rising compound hot - dry extremes engendering more inequality in human exposure risks[J]. npj Natural Hazards, 2025, 2: 66.

[4] REBETEZ M, MAYER H, DUPONT O, et al. Heat and drought 2003 in Europe: A climate synthesis[J]. Annals of Forest Science, 2006, 63 (6): 569-577.

[5] FENG S F, WU X Y, HAO Z C, et al. A database for characteristics and variations of global compound dry and hot events[J]. Weather and Climate Extremes, 2020, 30: 100299.

[6] ZSCHEISCHLER J, WESTRA S, VAN DEN HURK B J J M, et al. Future climate risk from compound events [J]. Nature Climate

- Change, 2018, 8(6): 469-477.
- [7] 张国涛,崔鹏,张晨笛. 中国山洪灾害防控理论与技术: 进展、挑战与对策[J]. 地理科学进展, 2025, 44(7): 1315-1333.
ZHANG G T, CUI P, ZHANG C D. Theory and technology of flash flood disaster prevention and control in China: Progress, challenges, and countermeasures [J]. Progress in Geography, 2025, 44(7): 1315-1333.
- [8] 宋晓猛,徐楠涛,张建云,等. 中国城市洪涝问题: 现状、成因与挑战[J]. 水科学进展, 2024, 35(3): 357-373.
SONG X M, XU N T, ZHANG J Y, et al. Urban flooding in China: current situation, causes and challenges [J]. Advances in Water Science, 2024, 35(3): 357-373.
- [9] PAN X L, WANG W G, SHAO Q X, et al. Compound drought and heat waves variation and association with SST modes across China[J]. Science of the Total Environment, 2024, 907: 167934.
- [10] COLLAZO S, BARRUCAND M, RUSTICUCCI M. Association between El Niño and extreme temperatures in southern South America in CMIP5 models. Part 1[J]. Climate Research, 2021, 83(2021): 111-132.
- [11] ZHAO R, ZHOU X, LIU J, et al. Projections of compound wet-warm and dry-warm extreme events in summer over China[J]. Journal of Hydrology, 2024, 639: 131635.
- [12] FENG S F, HAO Z C. Quantitative contribution of ENSO to precipitation-temperature dependence and associated compound dry and hot events[J]. Atmospheric Research, 2021, 260: 105695.
- [13] ZSCHEISCHLER J, MARTIUS O, WESTRA S, et al. A typology of compound weather and climate events[J]. Nature Reviews Earth & Environment, 2020, 1(7): 333-347.
- [14] HAO Z C, HAO F H, SINGH V P, et al. Changes in the severity of compound drought and hot extremes over global land areas [J]. Environmental Research Letters, 2018, 13(12): 124022.
- [15] HAO Y, HAO Z C, FENG S F, et al. Categorical prediction of compound dry and hot events in Northeast China based on large-scale climate signals[J]. Journal of Hydrology, 2021, 602: 126729.
- [16] 冯鑫,刘艳菊,童宏福,等. 基于海表温度和随机森林的珠江流域干旱预报模型研究[J]. 人民珠江, 2024, 45(5): 96-102.
FENG X, LIU Y J, TONG H F, et al. Drought prediction model of Pearl River Basin based on SST and machine learning [J]. Pearl River, 2024, 45(5): 96-102.
- [17] BI K F, XIE L X, ZHANG H H, et al. Accurate medium-range global weather forecasting with 3D neural networks [J]. Nature, 2023, 619(7970): 533-538.
- [18] 江善虎,刘梦飞,徐慧,等. 长江流域复合高温干旱时空演变特征分析[J]. 黑龙江大学工程学报(中英俄文), 2025, 16(2): 77-87.
JIANG S H, LIU M F, XU H, et al. Spatio-temporal evolution characteristics of compound hot-dry event in the Yangtze River Basin [J]. Journal of Engineering of Heilongjiang University, 2025, 16(2): 77-87.
- [19] HE R F, ZHANG L M, CHEW A W Z. Modeling and predicting rainfall time series using seasonal-trend decomposition and machine learning[J]. Knowledge-Based Systems, 2022, 251: 109125.
- [20] BELAYNEH A, ADAMOWSKI J, KHALIL B, et al. Long-term SPI drought forecasting in the Awash River Basin in Ethiopia using wavelet neural network and wavelet support vector regression models [J]. Journal of Hydrology, 2014, 508: 418-429.
- [21] LI J, WANG Z L, WU X S, et al. Robust meteorological drought prediction using antecedent SST fluctuations and machine learning [J]. Water Resources Research, 2021, 57(8): e2020WR029413.
- [22] QIN Y R, ZHANG Z J, WANG G H, et al. Spatiotemporal assessment and climate teleconnections of drought in Northeast China (2001—2023) using a machine-learning-based meteorological composite index[J]. Journal of Hydrology: Regional Studies, 2025, 61: 102693.
- [23] 方巍,庞林,王楠,等. 人工智能在短临降水预报中应用研究综述[J]. 南京信息工程大学学报(自然科学版), 2020, 12(4): 406-420.
FANG W, PANG L, WANG N, et al. Survey on the application of artificial intelligence in precipitation nowcasting [J]. Journal of Nanjing University of Information Science & Technology (Natural Science Edition), 2020, 12(4): 406-420.
- [24] 贾何佳,李谢辉,王磊,等. 基于机器学习的西南地区遥感干旱监测与评估[J]. 高原气象, 2022, 41(6): 1572-1582.
JIA H J, LI X H, WANG L, et al. Remote sensing drought monitoring and assessment in southwestern China based on machine learning[J]. Plateau Meteorology, 2022, 41(6): 1572-1582.
- [25] ALIZAMIR M, SHIRI J, FARD A F, et al. Improving the accuracy of daily solar radiation prediction by climatic data using an efficient hybrid deep learning model: Long short-term memory (LSTM) network coupled with wavelet transform[J]. Engineering Applications of Artificial Intelligence, 2023, 123: 106199.
- [26] LI J, WANG Z L, WU X S, et al. A standardized index for assessing sub-monthly compound dry and hot conditions with application in China[J]. Hydrology and Earth System Sciences, 2021, 25(3): 1587-1601.
- [27] FANG P, WANG T, YANG D, et al. Substantial increases in compound climate extremes and associated socio-economic exposure across China under future climate change [J]. npj Climate and Atmospheric Science, 2025, 8: 17.
- [28] WU X S, GUO S L, QIAN S N, et al. Long-range precipitation forecast based on multipole and preceding fluctuations of sea surface temperature [J]. International Journal of Climatology, 2022, 42(15): 8024-8039.
- [29] 赵轶琳,刘文丰,李政,等. 基于 STL 时序分解的天然径流演变规律与影响因素分析[J]. 水利学报, 2025, 56(2): 216-226.
ZHAO Y L, LIU W F, LI Z, et al. Analyses of the evolution and

influencing factors of natural runoff in China based on STL decomposition[J]. Journal of Hydroelectric Engineering, 2025, 56(2): 216-226.

[30] 熊怡, 周建中, 贾本军, 等. 基于随机森林遥相关因子选择的月径流预报[J]. 水力发电学报, 2022, 41(3): 32-45.

XIONG Y, ZHOU J Z, JIA B J, et al. Monthly runoff prediction based on teleconnection factors selection using random forest model[J]. Journal of Hydroelectric Engineering, 2022, 41(3): 32-45.

[31] BRÁZDIL R, ZAHRADNÍČEK P, DOBROVOLNY P, et al. Circulation and climate variability in the Czech republic between 1961 and 2020: A comparison of changes for two “normal” periods[J]. Atmosphere, 2022, 13(1): 137.

[32] DUAN Q Y, AJAMI N K, GAO X G, et al. Multi-model ensemble hydrologic prediction using Bayesian model averaging[J]. Advances in Water Resources, 2007, 30(5): 1371-1386.

[33] ADDISON-ATKINSON W, CHEN A S, RUBINATO M, et al. Quantifying flood model accuracy under varying surface complexities[J]. Journal of Hydrology, 2023, 620: 129511.

[34] MO K C, LETTENMAIER D P. Prediction of flash droughts over the United States[J]. Journal of Hydrometeorology, 2020, 21(8): 1793-1810.

[35] GILL A E. Some simple solutions for heat-induced tropical circulation[J]. Quarterly Journal of the Royal Meteorological Society, 1980, 106(449): 447-462.

[36] JI L Q, FAN K. Extreme heat waves in June 2021 over Europe regulated by shrinking Eurasian snow cover in mid-high latitudes[J]. Atmospheric Research, 2023, 295: 107049.

[37] 董少柔, 林爱兰, 董彦彤. 1961—2017 年华南区域性持续高温过程年际变化成因分析[J]. 大气科学, 2023, 47(5): 1325-1340.

DONG S R, LIN A L, DONG Y T. Analysis of interannual variation of regionally persistent High Temperature events in South China during 1961—2017[J]. Chinese Journal of Atmospheric Sciences, 2023, 47(5): 1325-1340.

(责任编辑 王海锋)