

# 基于多模型融合的椒江流域季节性径流集合预报

周 鹏,许月萍,周欣磊,刘 莉,梁 霄,郭玉雪

(浙江大学建筑工程学院,浙江 杭州 310058)

**摘要:**为提高季节性径流预报能力,分别耦合数值天气预报与新安江模型、分布式水文-土壤-植被(DHSVM)模型和长短期记忆网络(LSTM)模型对浙江省椒江流域 2012—2020 年的月径流量进行集合预报,采用等权重、不等权重和 BP 神经网络等不同方法对预报结果进行融合,比较了不同融合方法的预报效果与单一模型的最优预报效果。结果表明:BP 神经网络融合法显著提高了预报精度,明显优于其他方法,并在春、夏、秋、冬 4 个季节都大幅延长了有效预见期,能够为流域水资源管理与利用提供更为准确的水情预报信息。

**关键词:**季节性径流预报;新安江模型;DHSVM 模型;LSTM 模型;多模型融合;椒江流域

**中图分类号:**TV213.4

**文献标志码:**A

**文章编号:**1006-7647(2025)03-0062-08

**Ensemble forecasting of seasonal streamflow in the Jiaojiang River Basin based on multi-model fusion//ZHOU Peng, XU Yueping, ZHOU Xinlei, LIU Li, LIANG Xiao, GUO Yuxue (College of Civil Engineering and Architecture, Zhejiang University, Hangzhou 310058, China)**

**Abstract:** In order to enhance the predictability of seasonal streamflow, numerical weather prediction was coupled with the Xin'anjiang model, the distributed hydrological soil vegetation model (DHSVM), and the long short-term memory model (LSTM) for ensemble forecasting of monthly streamflow in the Jiaojiang River Basin from 2012 to 2020. Three different methods, namely, equal weighting, unequal weighting, and BP neural network-based weighting, were employed to fuse the outputs from the three models. Comparison was made between the fused forecasts and the optimal forecasts of single models. The results indicate that the BP neural network fusion method significantly enhances the forecasting accuracy, demonstrating superior performance over other methods. Notably, this method substantially extends the effective forecast lead time across all four distinct seasons (spring, summer, autumn, and winter), thereby providing more reliable hydrological predictions for water resources management and utilization in the basin.

**Key words:** seasonal streamflow forecasting; Xin'anjiang model; DHSVM model; LSTM model; multi-model fusion; the Jiaojiang River Basin

随着区域经济发展、气候变化加剧以及自然资源开发与环境保护意识的增强,流域内各部门对水文预报的精度及其预见期的要求越来越高。得益于计算机技术、流体力学、动力气象学等学科的发展,数值天气预报系统可以提供长预见期内高时空分辨率的气象集合预报数据,基于数值天气预报的季节性水文集合预报方法被提出并得到了广泛应用<sup>[1-2]</sup>。除了能提供预见期长达数月的水文信息,季节性水文集合预报结果还可以提供包含不确定信息的概率预测,从而满足不同的决策需求<sup>[3]</sup>。

水文模型是开展径流预报的重要工具。流域水文模型通常分为概念性模型、物理模型和黑箱模

型<sup>[4]</sup>。对于径流预报,不同类别模型有各自的优势与局限,单一模型不可能在所有情况下都能提供优于其他模型的预报结果<sup>[5]</sup>,因此需要通过适当的方法将多个单一模型预报融合在一起形成融合预报,发挥各个模型的优势,提高流域水文预报的准确性和可靠性。目前使用广泛的融合方法包括等权重平均法、不等权重平均法、贝叶斯平均法、模糊推理法和神经网络法等<sup>[6-10]</sup>。其中神经网络法具有表征学习能力强、灵活性和可扩展性高的特点,能够实现多输入-输出的处理并较好地捕捉数据的多模态特征,在多模型融合水文气象预报中取得了良好的应用效果<sup>[11-16]</sup>。例如:路志英等<sup>[17]</sup>使用多输入单输出的多

**基金项目:**国家重点研发计划项目(2021YFD1700802);浙江省自然科学基金重点项目(LZ20E090001)

**作者简介:**周鹏(1998—),男,硕士研究生,主要从事水文预报研究。E-mail:22112096@zju.edu.cn

**通信作者:**许月萍(1975—),女,教授,博士,主要从事水文水资源研究。E-mail:yuepingxu@zju.edu.cn

层反向传播神经网络 (BPNN) 对 3 个不同结构类型的模型进行融合气象预报,提高了预报的准确率;熊立华等<sup>[9]</sup>选用自适应神经模糊推理法对新安江模型和总径流响应模型的结果进行融合处理,得到了更稳健的流量模拟效果;陈昕等<sup>[18]</sup>运用基于人工神经网络方法的多模型输出集合系统对 4 个水文模型的模拟结果进行融合,融合结果相比单一结果大幅提高了精度。

椒江是浙江省台州市的母亲河,对区域内水资源供给具有重要作用,但近年来椒江流域面临着严重的水资源短缺问题,例如在 2020 年冬季椒江流域遭遇了 50 年一遇的旱情,造成区域水资源严重短缺。因此,对椒江流域开展季节性径流预报研究具有重要的实际应用价值。季节性预报可以有效地提供长期的水情信息,对水资源管理至关重要。为研究季节性径流集合预报在椒江流域的可预报性、提高预报精度以及延长预报有效预见期,本文选取概念性模型(新安江模型)、分布式水文模型(分布式水文-土壤-植被(DHSVM)模型)和深度学习模型(长短期记忆网络(LSTM)模型)进行率定和验证,再使用后处理后的数值预报结果驱动 3 个模型进行预报,最后采用等权重、不等权重和 BPNN 3 种融合方法对 3 个水文模型的预报结果进行融合,比较单一模型和不同融合预报的效果,并进一步分析融合预报在不同季节的改善程度。

# 1 研究区概况和数据来源

## 1.1 研究区概况

椒江流域主要位于浙江省台州市境内,流域总面积约 6600 km<sup>2</sup>,干流长 209 km,是浙江省第三大水系。流域属于亚热带季风气候,多年平均气温为 17.2℃,年平均湿度为 80%,多年平均降水量为 1 376.8 mm。流域四季分明,降雨主要集中在春末至秋末,尤其是夏季。降水是椒江流域径流的主要补给,其径流量年内分配主要集中在 4—10 月,约占全年总径流量的 70%。永安市和始丰溪是椒江流域上游的两条主要支流,自西向东流。两条支流在临海市三江村汇合后流入台州湾,最终排入东海<sup>[19]</sup>。

流域内共有雨量站 35 个、蒸发站 7 个、流量站 2 个,如图 1 所示。获取的雨量站逐日降水量和蒸发站逐日蒸发量记录时间段均为 2000—2020 年。柏枝岙和沙段流量站分别是永安市流域和始丰溪流域的出口断面径流控制站。柏枝岙站的逐日流量记录时间段为 1957—2020 年,沙段站的逐日流量记录时间段为 1980—2020 年。




图 1 研究区地理位置及水文气象站点分布

## 1.2 降水预报数据

降水预报数据采用美国国家环境预测中心(National Center for Environmental Prediction, NCEP)发布的第二代业务预报系统(Climate Forecast System version 2, CFSv2)的 4 个时段未来 9 月的降水预报<sup>[20]</sup>。该数据的空间分辨率为 0.9375°×0.947°,时间分辨率为 6 h。降水预报下载自网址(<https://www.ncei.noaa.gov/data/climate-forecast-system/access/>),所下载预报文件发布日期时间范围为 2011 年 4 月 1 日至 2020 年 12 月 31 日。

## 1.3 高程、土壤类型和植被类型数据

高程数据下载自国家地理空间数据云(<https://www.gscloud.cn/>),分辨率为 30 m×30 m。土壤类型数据下载自世界土壤数据库(<https://www.fao.org/soils-portal/soil-survey/soil-maps-and-databases/harmonized-world-soil-database-v12/en/>),该数据库中的中国土壤数据集由 2009 年采集的空间分辨率为 10 km×10 km 的网格数据构成,提供了各个格网点的土壤类型、土壤相位、土壤理化性状等信息。植被类型数据下载自全球土地覆盖数据库(<https://data-starcloud.pcl.ac.cn/iearthdata/>),分辨率为 30 m×30 m。

# 2 研究方法

## 2.1 水文模型构建

本文在椒江流域构建了 3 种不同类型的水文模型,分别为新安江模型<sup>[21]</sup>、DHSVM 模型<sup>[22]</sup>和 LSTM 模型<sup>[23]</sup>,其中前两者为物理过程模型,LSTM 模型为数据驱动模型。

### 2.1.1 新安江模型

在新安江模型中,永安市流域被划分为 8 个产汇流子单元,始丰溪流域被划分为 6 个产汇流子单元。模型输入为每个产汇流子单元的逐日面降水量和蒸散发量。面降水量通过泰森多边形由雨量站数据加权得到,面蒸散发量用最邻近蒸发站数据替代。椒江流域受人类活动影响主要体现在流域上游的大

中型水库,如里石门、龙溪和下岸水库,这些水库是区域内防洪、灌溉和供水的重要工程设施。在构建新安江模型过程中,流域上游水库区域的产流用出库流量替代。选择 NAGA-II 遗传算法作为新安江模型参数的自动优选方法。目标函数为纳什效率系数(NSE)和相对误差,以最大化 NSE 和最小化相对误差为率定准则。

为了更好地利用站点数据并确保模型具有鲁棒性,采用交叉验证方法,将 2000—2020 年划分为率定期和验证期,验证期为 2011—2015 年和 2016—2020 年,其余年份作为相应的率定期。

### 2.1.2 DHSVM 模型

在 DHSVM 模型中,模型输入为流域边界属性(mask)、气象数据、数字高程(DEM)、土壤类型、植被类型、土壤深度和河网数据。使用 ArcGIS 工具箱裁剪得到流域范围内的 DEM、土壤类型数据和植被类型数据,并对原始 DEM 进行填洼处理,采用地表径流漫流方法进行河网计算,提取出 mask 文件。使用流域内实测站点数据得到模型输入所需的降水量和蒸散发量。对模型参数进行敏感性分析,选取对模拟效果影响较大的参数进行率定。根据敏感性分析结果,选择 8 个参数参与率定,分别为降雨截留 LAI 加倍因子、土壤水侧向饱和传导率、土壤孔隙度、林冠覆盖率、上冠层月反照率、上冠层月叶面积指数、不饱和水汽压和参与光合作用的短波辐射。同样使用 NAGA-II 遗传算法进行参数自动优化,目标函数与新安江模型一致。采用同样的交叉验证方法,率定和验证期为 2000—2020 年。

### 2.1.3 LSTM 模型

在 LSTM 模型中,驱动因子为流域内雨量站月平均降水量,对降水序列和径流量序列进行互相关分析,确定滞时数为 3,即用连续 3 月的降水(即滞后 2 月、滞后 1 月和当月)去预测当月的径流量。模型使用 Adam 优化算法经反复迭代更新网络权重系数矩阵,并选取均方误差(MSE)指标作为损失函数,训练迭代次数为 200 次,每组训练样本大小为 16。采用同样的交叉验证方法,率定和验证期为 2000—2020 年。

## 2.2 多水文模型径流预报

### 2.2.1 降水预报集合方式

按照 CFSv2 集合预报的操作指南<sup>[24]</sup>,可以选取距离每月初较近的所有预报文件作为该月的预报成员。本文选取每月 1 日前后 14 天发布的所有预报作为相应月份的预报集合,构成拥有 112(28×4)个成员的集合预报。例如选取 2015 年 1 月 18 日至 2015 年 2 月 14 日发布的所有预报作为 2015 年 2 月

起报的预报成员,这些预报的第 1~28 天结果(2015 年 2 月有 28 天)作为 2015 年 2 月的当月预报(预见期记作 1 月),第 29~59 天结果(2015 年 3 月有 31 天)作为 2015 年 3 月的提前 1 月预报集合(预见期记作 2 月),以此类推,完成预见期 1~9 月的所有预报。

### 2.2.2 降水预报后处理和单模型径流集合预报

气候模式产生的数值降水预报产品精度不高,需要进行集合后处理后再去驱动水文模型。本文使用分位数映射法(quantile mapping, QM)对原始降水预报进行后处理。首先将 CFSv2 所有 112 个成员的格点预报数据通过反距离权重法(inverse distance weight, IDW)插值到流域内雨量站位置,再进行 QM 后处理,具体步骤如下:

- a. 计算实测降水和预报降水的经验累积分布函数(ECDF)。
- b. 利用线性插值法得到每个初始预报值在预报 ECDF 中的分位数,并将同等分位数的实测值与预报值的差值作为偏差纠正量。
- c. 每个初始预报值加上对应的偏差纠正量即修正后的预报降水。
- d. 对所有站点以及所有预见期重复上述后处理步骤。

最后将经过 QM 后处理的降水预报分别输入到所构建的 3 个水文模型中,以输出预见期为 1~9 月的季节性径流预报。本文预报期为 2012—2020 年,预报评估对象为每月平均径流量。

## 2.3 多模型融合方法

### 2.3.1 等权重融合法

等权重融合法是最简单的融合方法,它对所有模型的预报结果赋予相同的权重,3 个模型所有预报成员的结果取平均即得到融合预报结果,该方法可记作 MM1 法。等权重融合法不能充分利用预报技能更高的模型,因此,更适用于被融合成员预报技能比较均衡的场景。

### 2.3.2 不等权重融合法

不等权重融合法是根据不同模型集合预报在每个时间点的连续分级概率评分(CRPS)来进行权重分配,记为 MM2 法,其表达式为

$$F_{MM2} = \sum_{t=1}^T \sum_{n=1}^N w_{nt} F_{nt} \tag{1}$$

其中

$$w_{nt} = \lambda / C_{nt}$$

式中: $F_{MM2}$  为不等权重融合预报结果; $w_{nt}$  为模型  $n$  在时间点  $t$  参与融合的分配权重; $C_{nt}$  为模型  $n$  在时间点  $t$  的 CRPS; $\lambda$  为标准化因子,确保所有权重之和为 1。



不等权重融合法根据评估期预报成员的表现给予预报技能更高的成员更高的权重,该方法可以更好地利用成员的预报技能,但是应用前提是预报成员的预报技能是较为稳定的。

2.3.3 BPNN 融合法

BPNN 是通过对比误差反向传播算法训练的多层前馈神经网络,通常由输入层、隐藏层和输出层构成<sup>[25]</sup>,其学习过程包括信息正向传播和误差反向传播。输入变量从输入层经过隐藏层进行非线性处理,直至到达输出层。若输出层未达到预期结果,则计算输出层的误差变化值,然后进行反向传播并根据预测误差调整网络权重和阈值。

本文以 3 个模型的径流预报值为输入变量,以融合后的径流预报值为输出变量,对每一个预报成员均进行上述操作,采用含有一层隐藏层的 3 层 BPNN,构建了基于 BPNN 的多模型融合方法,记作 MM3 法。网络的最大迭代次数为 500,初始学习率为 0.000 1,优化器选择 Adam,各个神经元之间的传递函数选择 Sigmoid 函数。输入层节点数为 3,隐藏层节点数为 16,输出层节点数为 1。批次大小 (batch size) 设置为 32,训练集与测试集的划分比例为 7 : 3,采用早停法 (early stopping) 来防止网络模型过拟合。

BPNN 融合法适用于数据序列比较充分的情况。

2.4 评估指标

本文选取确定性指标纳什效率系数 (NSE) 和相对均方根误差 (RRMSE) 来评估集合平均预报结果 (等权重数学平均) 的精度,并使用概率性指标连续分级概率技巧评分 (CRPSS) 来评估集合预报的预报能力<sup>[26]</sup>。NSE 越大、RRMSE 越小说明预报精度越高。CRPSS 是评估集合预报结果与参考集合预报结果均一化后的得分,本文参考集合预报结果为历史实测径流集合。CRPSS 大于 0 说明评估预报结果比参考预报结果更具备预报能力,越接近 1 越好。

3 结果与分析

3.1 单一模型率定验证结果

表 1 为 3 个模型在月尺度的交叉率定验证结果,呈现的指标为 2 个折叠期指标结果的平均值。由表 1 可知,3 个模型在验证期的 NSE 和率定期非常接近,说明所构建模型具有较好的泛化性。其中新安江模型在率定期和验证期的 NSE 均超过 0.93,DHSVM 模型在率定期和验证期的 NSE 均在 0.90 附近,LSTM 模型在率定期和验证期的 NSE 均超过 0.85。

表 1 3 个水文模型在研究流域的率定和验证结果

| 模型    | 出口流量站 | 率定期  |        | 验证期  |        |
|-------|-------|------|--------|------|--------|
|       |       | NSE  | 相对误差/% | NSE  | 相对误差/% |
| 新安江   | 柏枝岙   | 0.94 | 1.4    | 0.93 | 5.2    |
|       | 沙 段   | 0.97 | 0.6    | 0.96 | -0.7   |
| DHSVM | 柏枝岙   | 0.91 | 4.5    | 0.90 | 2.4    |
|       | 沙 段   | 0.91 | 2.1    | 0.89 | -3.2   |
| LSTM  | 柏枝岙   | 0.88 | -0.1   | 0.87 | 0.1    |
|       | 沙 段   | 0.86 | -0.6   | 0.85 | -4.0   |

图 2 为 2011—2020 年椒江流域两个流量站实测月平均径流与模拟结果的散点图,按照实测序列的 0~25、>25~75、>75~100 分位数区间划分为低流量、中流量、高流量月份,并在不同流量级别中使用线性回归方法对不同模型的散点图进行拟合。由图 2 可知,在低流量月份中,新安江模型的模拟结果最靠近 1 : 1 线而且分布比较对称,DHSVM 模型大部分模拟结果低于 1 : 1 线,LSTM 模型整体模拟高于 1 : 1 线;在中流量月份中,新安江模型模拟结果大部分高于 1 : 1 线,DHSVM 模型模拟结果大部分低于 1 : 1 线,LSTM 模型模拟结果相对来说对称性最好;在高流量月份中,LSTM 模型模拟结果大部分低于 1 : 1 线,新安江模型和 DHSVM 模型在柏枝岙站的模拟结果大部分偏高,在沙段站的模拟结果大部分偏低,DHSVM 模型结果相对更接近 1 : 1 线。




图 2 椒江流域柏枝岙站和沙段站验证期 (2011—2020 年) 月平均径流实测值与模拟值对比



3.2 融合预报分析

3.2.1 不同水文模型的权重分析

为分析不同水文模型在不同预见期和不同级别流量事件中的权重贡献率,本文对不等权重融合法和 BPNN 融合法中 3 个水文模型在 2 个研究流域多模型融合过程中的权重贡献率做了统计(表 2),其中 Q1、Q2、Q3 分别代表高流量月份、中流量月份和低流量月份。由于等权重融合法中所有模型在不同预见期 and 不同流量事件的权重贡献率相同,因此不参与统计。

表 2 不同水文模型在多模型融合中的权重贡献率

| 预见期/月 | 流域  | 流量类别 | 多模型融合权重贡献率/% |       |      |
|-------|-----|------|--------------|-------|------|
|       |     |      | 新安江          | DHSVM | LSTM |
| ≤3    | 永安溪 | Q1   | 30.9         | 55.5  | 13.6 |
|       |     | Q2   | 31.5         | 9.3   | 59.2 |
|       |     | Q3   | 60.5         | 14.8  | 24.7 |
|       | 始丰溪 | Q1   | 28.5         | 60.4  | 11.1 |
|       |     | Q2   | 37.7         | 10.5  | 51.8 |
|       |     | Q3   | 77.8         | 5.0   | 17.2 |
| >3    | 永安溪 | Q1   | 37.6         | 13.6  | 48.8 |
|       |     | Q2   | 29.0         | 10.8  | 60.2 |
|       |     | Q3   | 27.2         | 38.3  | 34.5 |
|       | 始丰溪 | Q1   | 68.5         | 11.7  | 19.8 |
|       |     | Q2   | 33.2         | 13.3  | 53.5 |
|       |     | Q3   | 37.0         | 42.6  | 20.4 |

统计结果显示,在短预见期(3 月之内),高、中、

低流量月份的融合权重贡献率分别主要来自 DHSVM 模型、LSTM 模型、新安江模型。这和 3 个模型在不同等级流量中的模拟表现一致。DHSVM 模型相对更擅长高流量月份的模拟,可能是因为 DHSVM 模型能够较为精细地模拟地表径流和快速径流的形成过程,而这些过程在高流量时段更为显著。LSTM 模型在中流量月份贡献较大,可能是因为训练过程中流量数据样本占比较大,使得 LSTM 模型对中流量序列的学习能力较强。新安江模型能较好地模拟土壤水分的累积和地下水的补给过程,这些过程在低流量时段更为重要。当预见期超过 3 月,DHSVM 模型在高流量月份的权重贡献率大幅下降,高、中流量月份的融合权重贡献率主要来自新安江模型和 LSTM 模型,这可能是数值降水预报精度下降造成的影响,在较长预见期中,数值降水预报系统会严重低估高流量月份的降水量,从而导致 DHSVM 模型在高流量月份的预报优势消失。

3.2.2 不同融合预报方法的结果比较

图 3 展示了不同预见期中多模型融合预报方法的集合平均预报序列,表 3 统计了单一模型最优预报法(记作 SMO 法)与 3 种融合预报方法(等权重融合法、不等权重融合法、BPNN 融合法)的评估结果。限于篇幅,图表中仅展示柏枝岙站计算结果。




图 3 基于多模型融合方法的径流预报序列(柏枝岙站)

表 3 单一模型最优预报法与 3 种融合预报方法的评估结果

| 预见期/月 | NSE   |       |       |      | RRMSE/% |      |      |      | CRPSS |       |       |      |
|-------|-------|-------|-------|------|---------|------|------|------|-------|-------|-------|------|
|       | SMO   | MM1   | MM2   | MM3  | SMO     | MM1  | MM2  | MM3  | SMO   | MM1   | MM2   | MM3  |
| 1     | 0.56  | 0.57  | 0.68  | 0.78 | 57.8    | 57.5 | 49.1 | 40.9 | 0.19  | 0.18  | 0.33  | 0.41 |
| 2     | 0.27  | 0.23  | 0.46  | 0.70 | 74.4    | 76.8 | 64.2 | 47.3 | -0.13 | -0.17 | 0.04  | 0.30 |
| 3     | 0.12  | 0.07  | 0.33  | 0.66 | 81.6    | 83.9 | 71.7 | 50.4 | -0.22 | -0.26 | -0.05 | 0.28 |
| 4     | 0.01  | -0.05 | 0.11  | 0.60 | 87.1    | 89.7 | 82.3 | 47.4 | -0.30 | -0.34 | -0.19 | 0.28 |
| 5     | -0.11 | -0.18 | -0.01 | 0.56 | 91.8    | 94.8 | 87.5 | 50.8 | -0.37 | -0.43 | -0.26 | 0.29 |
| 6     | -0.18 | -0.23 | -0.04 | 0.61 | 94.9    | 97.0 | 89.2 | 47.0 | -0.40 | -0.45 | -0.27 | 0.25 |
| 7     | -0.23 | -0.29 | -0.10 | 0.58 | 96.7    | 99.1 | 91.5 | 48.8 | -0.44 | -0.49 | -0.31 | 0.28 |
| 8     | -0.19 | -0.23 | -0.04 | 0.57 | 95.3    | 96.7 | 88.7 | 50.1 | -0.42 | -0.45 | -0.28 | 0.21 |
| 9     | -0.17 | -0.21 | -0.01 | 0.59 | 94.4    | 96.1 | 87.8 | 55.5 | -0.43 | -0.45 | -0.28 | 0.14 |

由图 3 可知,3 种融合预报方法在预见期为 1 月时均具有较好的径流预报效果,能够出色地捕捉流量的变化趋势,但是受限于参与融合水文模型的预报能力,3 种方法在一些极高流量月份中存在较明显的低估,在部分低流量月份中存在高估。随着预见期增加,等权重融合法和不等权重融合法迅速失去预报能力,预报序列不能较好地反映流量的变化趋势,BPNN 融合法的表现则相对稳定。由表 3 可知,3 种方法的精度和可靠性的迅速变差发生在预见期为 1~2 月的过程中,在预见期为 2~5 月的过程中持续变差,当预见期超过 5 月时,各项指标趋于稳定。BPNN 融合法的预报效果最优,然后依次为不等权重融合法和等权重融合法。等权重融合法的预报能力和单一模型最优预报法差别不大,相比单一模型最优预报法,不等权重融合法、BPNN 融合法分别将 NSE 平均提升 0.15、0.62,将 RRMSE 平均降低 6.9%、37.3%,将 CRPSS 平均提升 0.15、0.55。

3.2.3 不同季节径流预报预见期比较

图 4 展示了单一模型最优预报法和 3 种融合预报方法在不同季节的指标表现,格子中的 \* 表示相比参考集合预报更优的结果。当 CRPSS 大于 0 且

3 个评估指标同时优于参考集合预报时,可以认为预报是有效的。表 4 统计了不同预报方法在 4 个季节的有效预见期。由图 4 和表 4 可知,夏、秋两季的指标结果相对要优于春、冬两季,单一模型最优预报法在夏季的有效预见期达到 3 月,在春、秋两季的有效预见期均为 1 月,在冬季的有效预见期为 0 月。这表明单一模型在夏季的预报能力最强,在春、秋两季的表现有所下降,在冬季的预报能力最弱。等权重融合法在所有季节均没有延长有效预见期,这可能是因为简单的平均融合未能充分利用各个模型的优势和特点。不等权重融合法将春、秋、冬季的有效预见期分别延长至 2 月、6 月、1 月,相比等权重融合法有所改善,但在夏季仍未能延长有效预见期,这可能是因为基于 CRPS 的不等权重调整不够灵活,未能充分适应不同数据的季节差异。BPNN 融合法在 4 个季节都表现出色,除冬季(有效预见期 7 月)外所有季节的有效预见期均被延长至 9 月,远超前两种融合方法,这可能是因为 BPNN 有较强的非线性建模能力和自适应性,能通过不断的反向传播算法,自动调整神经元权重参数,充分考虑每个模型的结果,最大程度地利用了模型信息,以适应不同的预报




图 4 单一模型最优预报法与 3 种融合预报方法在不同季节的指标热力图(柏枝岙站)

场景和数据变化。

表 4 单一模型最优预报法与 3 种融合预报方法在不同季节的有效预见期

| 预报方法 | 有效预见期/月 |    |    |    |
|------|---------|----|----|----|
|      | 春季      | 夏季 | 秋季 | 冬季 |
| SMO  | 1       | 3  | 1  | 0  |
| MM1  | 1       | 2  | 1  | 0  |
| MM2  | 2       | 3  | 6  | 1  |
| MM3  | 9       | 9  | 9  | 7  |

综上所述,BPNN 融合法在季节性径流集合预报中具有较强的预报能力和适应性,能够提高预报的精确性并延长有效预见期。该方法为今后提高流域季节性径流集合预报能力提供了一个有效的思路。

3.3 研究展望

本文将不同机制(物理过程和数据驱动)、不同空间结构(半分布式和分布式)的季节性径流预报结果进行融合,得到了比单一预报更出色的融合预报结果,能够为流域水资源管理与利用提供更为准确的水情预报信息。未来可从以下几方面进行更深入的探索:

- a. 进一步优化多模型融合方法。考虑引入更多先进的机器学习算法如深度学习和强化学习,以提高融合效果。
- b. 更深入地考虑人类活动影响。受限于时间和研究水平,本文在构建 DHSVM 模型和 LSTM 模型的过程中并未考虑人类活动的影响,在后续的研究中应将其纳入模型中以提高预报的准确性和可靠性。
- c. 整合更多的数值预报数据和遥感数据,提升模型对实际情况的反映能力,特别是对极端事件的预报能力。

4 结 论

- a. 在短预见期(3 月之内),高、中、低流量月份的融合权重分别主要来自 DHSVM 模型、LSTM 模型、新安江模型;当预见期超过 3 月时,DHSVM 模型的融合贡献主要体现在低流量月份,高、中流量月份的融合权重主要来自新安江模型和 LSTM 模型。
- b. BPNN 融合法的预报效果最优,然后依次为等权重融合法和不等权重融合法,等权重融合法的预报能力和单一模型最优预报法差别不大,相比单一模型最优预报法,不等权重融合法、BPNN 融合法分别将 NSE 平均提升 0.15、0.62,将 RRMSE 平均降低 6.9%、37.3%,将 CRPSS 平均提升 0.15、0.55。融合预报各项指标的迅速变差发生在预见期为 1~2 月的过程中,在预见期为 2~5 月的过程中持续变

差,当预见期超过 5 月时,各项指标趋于稳定。

- c. 单一模型最优预报法在夏季的有效预见期达到 3 月,在春、秋两季的有效预见期均为 1 月,在冬季的有效预见期为 0 月。等权重融合法在所有季节均没有能够延长有效预见期,不等权重融合法将春、秋、冬季的有效预见期分别延长至 2 月、6 月、1 月。BPNN 融合法表现最为出色。

参考文献:

[ 1 ] 金君良,舒章康,陈敏,等. 基于数值天气预报产品的气象水文耦合径流预报[J]. 水科学进展,2019,30(3): 316-325. ( JIN Junliang, SHU Zhangkang, CHEN Min, et al. Meteo-hydrological coupled runoff forecasting based on numerical weather prediction products [J]. Advances in Water Science, 2019, 30(3): 316-325. (in Chinese) )

[ 2 ] 赵铜铁钢,张弛,田雨,等. 全球气象预报驱动流域水文预报研究进展与展望[J]. 水科学进展,2024,35(1): 156-166. ( ZHAO Tongtiegang, ZHANG Chi, TIAN Yu, et al. Research progresses and prospects of catchment hydrological forecasting driven by global climate forecasts [J]. Advances in Water Science, 2024, 35(1): 156-166. (in Chinese) )

[ 3 ] LIU Li, GAO Chao, XUAN Weidong, et al. Evaluation of medium-range ensemble flood forecasting based on calibration strategies and ensemble methods in Lanjiang Basin, Southeast China [J]. Journal of Hydrology, 2017, 554: 233-250.

[ 4 ] 芮孝芳. 论流域水文模型[J]. 水利水电科技进展, 2017, 37(4): 1-7. ( RUI Xiaofang. Discussion of watershed hydrological model [J]. Advances in Science and Technology of Water Resources, 2017, 37(4): 1-7. (in Chinese) )

[ 5 ] 徐静,叶爱中,毛玉娜,等. 水文集合预报研究与应用综述[J]. 南水北调与水利科技,2014,12(1): 82-87. ( XU Jing, YE Aizhong, MAO Yu' na, et al. Review of research and application of hydrologic ensemble forecast [J]. South-to-North Water Transfers and Water Science & Technology, 2014, 12(1): 82-87. (in Chinese) )

[ 6 ] 梁忠民,戴荣,王军,等. 基于贝叶斯模型平均理论的水文模型合成预报研究[J]. 水力发电学报,2010, 29(2): 114-118. ( LIANG Zhongmin, DAI Rong, WANG Jun, et al. Study on forecast combination of different hydrological models by Bayesian model averaging [J]. Journal of Hydroelectric Engineering, 2010, 29(2): 114-118. (in Chinese) )

[ 7 ] GAO Jing, LI Peng, CHEN Zhikui, et al. A survey on deep learning for multimodal data fusion [J]. Neural Computation, 2020, 32(5): 829-864.

[ 8 ] RAFTERY A E, GNEITING T, BALABDAOUI F, et al. Using Bayesian model averaging to calibrate forecast



- ensembles[J]. Monthly Weather Review, 2005, 133(5): 1155-1174.
- [9] 熊立华,郭生练,叶凌云. 自适应神经模糊推理系统 (ANFIS) 在水文模型综合中的应用[J]. 水文, 2006, 26(1): 38-41. (XIONG Lihua, GUO Shenglian, YE Lingyun. Application of ANFIS in the combination of hydrological models [J]. Journal of China Hydrology, 2006, 26(1): 38-41. (in Chinese))
- [10] 李宏亮. 基于三种中长期预报模型的集合预报模型在漓江桂林段的应用[J]. 中国农村水利水电, 2019(11): 33-37. (LI Hongliang. The application of ensemble forecasting model based on three long-term runoff forecasting models in Guilin section of the Lijiang River [J]. China Rural Water and Hydropower, 2019(11): 33-37. (in Chinese))
- [11] 崔东文. 多重组合神经网络模型在年径流预测中的应用[J]. 水利水电科技进展, 2014, 34(2): 59-63. (CUI Dongwen. Application of multiple combined neural network model in annual runoff prediction [J]. Advances in Science and Technology of Water Resources, 2014, 34(2): 59-63. (in Chinese))
- [12] 崔东文. 多组群教学优化算法-神经网络-支持向量机组合模型在径流预测中的应用[J]. 水利水电科技进展, 2019, 39(4): 41-48. (CUI Dongwen. Combined model of multi-group teaching optimization algorithm-neural network-support vector machine in runoff prediction application [J]. Advances in Science and Technology of Water Resources, 2019, 39(4): 41-48. (in Chinese))
- [13] 孙周亮,刘艳丽,张建云,等. 中长期径流预报研究进展与展望[J]. 水资源保护, 2023, 39(2): 136-144. (SUN Zhouliang, LIU Yanli, ZHANG Jianyun, et al. Research progress and prospect of mid-long term runoff prediction [J]. Water Resources Protection, 2023, 39(2): 136-144. (in Chinese))
- [14] 石卓,史东华,姚成,等. 基于径流模数的 LSTM 模型在无资料嵌套流域的应用[J]. 河海大学学报(自然科学版), 2024, 52(3): 51-57. (SHI Zhuo, SHI Donghua, YAO Cheng, et al. Application of runoff modulus-based LSTM in ungauged nested watersheds [J]. Journal of Hohai University (Natural Sciences), 2024, 52(3): 51-57. (in Chinese))
- [15] 刘莉,梁霄, WANG Quanjun, 等. 基于深度学习的改进 ERRIS 径流预报实时校正模型[J]. 水资源保护, 2024, 40(6): 155-164. (LIU Li, LIANG Xiao, WANG Quanjun, et al. Improved ERRIS model for real-time correction of streamflow forecast based on deep learning [J]. Water Resources Protection, 2024, 40(6): 155-164. (in Chinese))
- [16] 李菊,崔东文. 基于 WPT-IDBO-RELM 和 WPT-IDMO-RELM 模型的日径流预测[J]. 水利水电科技进展, 2024, 44(6): 48-55. (LI Ju, CUI Dongwen. Daily runoff prediction based on WPT-IDBO-RELM and WPT-IDMO-RELM models [J]. Advances in Science and Technology of Water Resources, 2024, 44(6): 48-55. (in Chinese))
- [17] 路志英,赵智超,郝为,等. 基于人工神经网络的多模型综合预报方法[J]. 计算机应用, 2004, 24(4): 50-51. (LU Zhiying, ZHAO Zhichao, HAO Wei, et al. Multi-model ensemble forecast method based on ANN [J]. Computer Applications, 2004, 24(4): 50-51. (in Chinese))
- [18] 陈昕,鱼京善. 基于人工神经网络的雅砻江流域水文过程多模型集合模拟[J]. 南水北调与水利科技, 2018, 16(2): 74-80. (CHEN Xin, YU Jingshan. Multi-model ensemble hydrological simulation of Yalong River Basin based on artificial neural network [J]. South-to-North Water Transfers and Water Science & Technology, 2018, 16(2): 74-80. (in Chinese))
- [19] LIU Li, GU Haiting, XU Yueping, et al. Real-time flood forecasting via parameter regionalization and blending nowcasts with NWP forecasts over the Jiao River, China [J]. Journal of Hydrometeorology, 2023, 24(3): 561-582.
- [20] LUO Lifeng, TANG Wei, LIN Zhaohui, et al. Evaluation of summer temperature and precipitation predictions from NCEP CFSv2 retrospective forecast over China [J]. Climate Dynamics, 2013, 41(7/8): 2213-2230.
- [21] 赵人俊. 流域水文模拟: 新安江模型与陕北模型[M]. 北京: 水利电力出版社, 1984.
- [22] WIGMOSTA M S, VAIL L W, LETTENMAIER D P. A distributed hydrology-vegetation model for complex terrain [J]. Water Resources Research, 1994, 30(6): 1665-1679.
- [23] SMAGULOVA K, JAMES A P. A survey on LSTM memristive neural network architectures and applications [J]. The European Physical Journal Special Topics, 2019, 228(10): 2313-2324.
- [24] SAHA S, MOORTHY S, WU Xingren, et al. The NCEP climate forecast system version 2 [J]. Journal of Climate, 2014, 27(6): 2185-2208.
- [25] 王日莲,董曼玲. 人工神经网络在水文预报中的应用[J]. 水利水电科技进展, 2002, 22(5): 33-34. (WANG Rilian, DONG Manling. Application of artificial neural network to hydrological prediction [J]. Advances in Science and Technology of Water Resources, 2002, 22(5): 33-34. (in Chinese))
- [26] HERSBACH H. Decomposition of the continuous ranked probability score for ensemble prediction systems [J]. Weather and Forecasting, 2000, 15(5): 559-570.

(收稿日期: 2024-05-08 编辑: 俞云利)