

# 机器学习算法在降水和气温多模式集成中的应用

鞠琴<sup>1,2</sup>, 吴金雨<sup>1,2</sup>, 王兴平<sup>3</sup>, 刘小妮<sup>1,2</sup>, 王逸夫<sup>1,2</sup>, 段远强<sup>1,2</sup>, 吴可馨<sup>1,2</sup>, 蒋晓蕾<sup>1,4</sup>

(1. 河海大学水灾害防御全国重点实验室, 江苏 南京 210098; 2. 中国气象局水文气象重点开放实验室, 江苏 南京 210024; 3. 四川省紫坪铺开发有限责任公司, 四川 成都 610091; 4. 扬州大学水利科学与工程学院, 江苏 扬州 225000)

**摘要:**选取 CMIP6 中 5 种全球气候模式, 利用算术平均、权重平均、多元线性回归、BP 神经网络、长短期记忆 (LSTM) 神经网络和随机森林 (RF) 等 6 种多模式集成方法, 基于黄河流域水源涵养区历史降水量和气温数据, 评估不同集成方法的模拟效果, 并选取模拟效果最好的多模式集成方法预估未来 SSP1-2.6、SSP2-4.5 和 SSP5-8.5 3 种情景下黄河流域水源涵养区的降水和气温变化趋势。结果表明: 多模式集成能很好地再现基准期降水和气温变化, 3 种机器学习算法表现相对较好, 其中 LSTM 神经网络最好; 在未来 3 种情景下, 多年平均降水量均有所增加, 四季降水量变化各有差异; SSP1-2.6 情景下年降水量峰值出现在各时段初期, SSP2-4.5 和 SSP5-8.5 情景下的年降水量呈增长趋势, 远期下降趋势较明显; 3 种情景下气温都呈上升趋势, 但变化差异较大, 增温幅度和速率由小到大为 SSP1-2.6、SSP2-4.5、SSP5-8.5, 秋季气温增幅最大, 冬季最小; 多模式集成方法对未来降水量和气温的预估存在较大的不确定性, 均表现为中远期大于近期, 降水量预估的不确定性比气温大, 其中降水量秋冬季不确定性明显大于春夏季。

**关键词:** CMIP6; 全球气候模式; 多模式集成; LSTM 神经网络; 黄河流域

**中图分类号:** P468

**文献标志码:** A

**文章编号:** 1004-6933(2024)03-0106-10

**Application of machine learning algorithms in multimodal integration of precipitation and temperature**/JU Qin<sup>1,2</sup>, WU Jinyu<sup>1,2</sup>, WANG Xingping<sup>3</sup>, LIU Xiaoni<sup>1,2</sup>, WANG Yifu<sup>1,2</sup>, DUAN Yuanqiang<sup>1,2</sup>, WU Kexin<sup>1,2</sup>, JIANG Xiaolei<sup>1,4</sup> (1. The National Key Laboratory of Water Disaster Prevention, Hohai University, Nanjing 210098, China; 2. China Meteorological Administration Hydro-Meteorology Key Laboratory, Nanjing 210024, China; 3. Sichuan Province Zipingpu Development Co., Ltd., Chengdu 610091, China; 4. College of Hydraulic Science and Engineering, Yangzhou University, Yangzhou 225000, China)

**Abstract:** Using six multimodal integration methods, including arithmetic averaging, weighted averaging, multiple linear regression, BP neural network, long-short-term memory (LSTM) neural network, and random forest (RF), this study integrated five global climate models (GCMs) data in CMIP6, and based on historical precipitation and temperature data of the Yellow River Basin water conservation region, the simulation performance of different integration methods were evaluated. The multimodal integration method with the best performance was selected to predict future precipitation and temperature under three scenarios (SSP1-2.6, SSP2-4.5, and SSP5-8.5). The results show that the multimodal integration could well reproduce the variations of historical precipitation and temperature, and the LSTM neural network method has the best performance. In three scenarios, future average annual precipitation all increases, but the change of seasonal precipitation in the future varies. Under the SSP1-2.6 scenario, the annual precipitation peaks occur at the beginning of each period, while annual precipitation increases in the near term and decreases obviously in the long term under the SSP2-4.5 and SSP5-8.5 scenarios. Future temperature in three scenarios shows upward trends of different degrees, and the amplitude and rate of temperature increase from small to large are: SSP1-2.6, SSP2-4.5, SSP5-8.5. Future temperature increases greatest in autumn and least in winter. There are large uncertainties in the future precipitation and temperature predicted by multimodal integration methods, and the uncertainty in the medium to long term is greater than in the short term. The uncertainty in future precipitation projection is relatively greater than that of temperature, and

**基金项目:**国家重点研发计划项目(2021YFC3201104);中央高校基本科研业务费专项资金资助项目(B240203007);江苏省大学生创新创业项目(202310294012Z, 202310294176Y);水灾害防御全国重点实验室“一带一路”水与可持续发展科技基金项目(2022491111, 522012232)

**作者简介:**鞠琴(1980—),女,副教授,博士,主要从事气候变化下水文响应研究。E-mail:juqin@hhu.edu.cn

the uncertainty in autumn and winter is significantly greater than that in spring and summer.

**Key words:** CMIP6; global climate model; multimodal integration; long-short-term memory neural network; Yellow River Basin

气候变化引起干旱、洪涝等极端事件发生的强度与频率增加,对生态环境与人类生存有严重的威胁<sup>[1]</sup>。《中国气候变化蓝皮书(2022)》指出,2021年中国地表平均气温是过去近120年来的最高值,全球变暖趋势仍在持续<sup>[2]</sup>。全球变暖背景下的未来区域气候变化的预估受到众多学者的高度关注<sup>[3]</sup>。大气环流模式(general circulation models, GCMs)是气候科学研究中的重要工具,也是气候模拟和预测的基础。国际耦合模式比较计划(Coupled Model Intercomparison Project, CMIP)广泛应用于预估未来气候变化,最新的CMIP6通过结合典型浓度路径(representative concentration pathways, RCPs)和共享社会经济途径(shared socioeconomic pathways, SSPs),使未来情景更加现实<sup>[4-5]</sup>。利用单一模式或多个模式进行未来不同排放情景下全球和区域气候变化的预估,已成为当前研究的热点<sup>[6-7]</sup>,单模式模拟具有很大的不确定性,且通常与真实值存在较大的偏差<sup>[8-9]</sup>。吴金雨等<sup>[10]</sup>对黄河流域水源涵养区1985—2014年降水和气温的模拟能力进行综合评估,结果表明绝大多数模式对气温的模拟能力表现较好,对降水的模拟普遍存在较大的偏差。1999年,Krishnamurti等<sup>[11]</sup>首次提出了多模式超级集成预报思想,即以一定的统计学方法集成多个模式来获得最佳的预报结果<sup>[12-13]</sup>,此后的大量研究也表明多模式集成方法能够集成各模式的多样化信息,预测效果优于单模式。李芳<sup>[14]</sup>利用等权平均、订正后再等权平均、多元线性回归和贝叶斯模型平均集成5个海-气耦合模式,制作中国东部1960—2005年夏季降水的概率密度函数(probability density function, PDF)预测,结果表明中国东部各区域最优多模式集成方法的PDF预测技巧接近气候学预测。周梦瑶等<sup>[15]</sup>以1961—2000年赣江与汉江流域为研究区域,采用贝叶斯模型平均集成8个CMIP5模式的气温和降水,发现贝叶斯模型的模拟精度比单模式更高。马阳等<sup>[16]</sup>利用CMIP6模式模拟黄河流域宁夏段1961—2014年气温,发现集合平均的模拟效果优于单模式。近年来,随着人工智能的发展,机器学习算法取得了突破性进展,目前在气候研究中的应用十分广泛<sup>[17]</sup>。金浩宇等<sup>[18]</sup>基于6种CMIP5气候模式,探讨了包括BP神经网络机器学习算法在内的4种多模式集成方法在长江源区降水和气温的模拟能力,结果表明多模式集成效果优

于单模式,其中BP神经网络集成模拟效果最好。Dey等<sup>[5]</sup>对印度河流域采用了人工神经网络(artificial neural network, ANN)、随机森林(random forest, RF)模型和支持向量机(support vector machine, SVM)3种机器学习算法集成了5个CMIP6模式的降水和气温,结果表明SVM和RF模型优于ANN方法。由此可见,组合多个模式集成的结果可以减少单一模式初始场的不确定性及系统偏差,组合模式通常具有比任何单一模式更高的性能<sup>[19]</sup>。而采用何种集成方法获取未来较为准确的长序列气象要素成为研究的关键。机器学习算法可以从海量数据中提取有价值的信息,并高效地处理模式之间的非线性关系,基于机器学习的多模式集成方法能提高气象要素预估中的模拟精度<sup>[20]</sup>,不同多模式集成方法的改进效果存在差异,特别是该方法在气候变化敏感区的适用性还有待研究。

黄河流域是我国重要的生态屏障,水资源总量仅占我国的2%,却供给着我国12%的人口和15%的耕地用水<sup>[21]</sup>。黄河流域水源涵养区位于黄河流域上游,是黄河流域的主要水量来源区<sup>[22-23]</sup>,其产水量关系到整个黄河流域水资源总量。黄河流域水源涵养区在当前气候变化和人类活动的共同影响下,面临的水资源短缺、水土流失等问题日益严峻<sup>[24]</sup>。因此,本文选取CMIP6中的5种GCMs<sup>[10]</sup>,采用相对误差、相关系数、纳什效率系数等评估6种多模式集成方法(算术平均法、权重平均法、多元线性回归方法、BP神经网络、LSTM神经网络和RF模型)对黄河流域水源涵养区1985—2014年面平均降水和气温的模拟能力。预估期分为近期(2026—2045年)、中期(2046—2065年)和远期(2066—2085年),采用模拟效果最好的多模式集成方法,预估SSP1-2.6、SSP2-4.5和SSP5-8.53种情景下的3个时段的面平均降水和气温变化,以期为水资源管理利用和应对未来气候变化提供参考。

## 1 研究区概况与数据来源

### 1.1 研究区概况

黄河流域水源涵养区(32°12'N ~ 38°17'N、95°55'E ~ 113°7'E)地处中国西北干旱区,流域面积为30.44万km<sup>2</sup>,地势西高东低且相差较大。独特的地理位置和地貌特征造就了其独特的气候类型,流域生态环境脆弱,是气候变化的敏感区<sup>[22]</sup>,流

域地理位置及高程信息如图 1 所示。




图 1 黄河流域水源涵养区概况

Fig. 1 Overview of water conservation region of the Yellow River Basin

1.2 数据来源

设置基准期为 1985—2014 年,其中 1985—2009 年为率定期,2010—2014 年为验证期;预估期为 2026—2085 年。模式未来情景选择 SSP1-2.6、SSP2-4.5 和 SSP5-8.5 3 种情景,其中 SSP1-2.6 为低强迫情景,即 2100 年辐射强迫稳定在  $2.6\text{W/m}^2$ ; SSP2-4.5 为中等强迫情景,即 2100 年辐射强迫稳定在  $4.5\text{W/m}^2$ ; SSP5-8.5 为高强迫情景,即 2100 年辐射强迫稳定在  $8.5\text{W/m}^2$  [25]。采用中国区域地面气象要素驱动数据集中的降水和气温作为观测资料,数据来自国家青藏高原科学数据中心 (<https://data.tpdc.ac.cn>),分辨率为  $0.1^\circ\times0.1^\circ$ ,数据精度较高,是中国地区使用最广泛的气候数据集之一 [26-27]。基于已有的黄河流域水源涵养区 CMIP6 气候模式降水和气温评估研究 [10],结合未来 3 种情景下模式数据的完整性,CMIP6 模式的选择如表 1 所示,使用双线性插值法 [28] 将这 5 种模式数据的分辨率插值到与观测值相同。

表 1 CMIP6 全球气候模式选择

Table 1 CMIP6 global climate model selection

| 气候模式          | 研究机构     | 国家 | 径向分辨率/(°) | 纬向分辨率/(°) |
|---------------|----------|----|-----------|-----------|
| EC-Earth3     | EC-Earth | 瑞典 | 0.703     | 0.703     |
| EC-Earth3-Veg | EC-Earth | 瑞典 | 0.703     | 0.703     |
| FGOALS-g3     | IAP, CAS | 中国 | 2.000     | 2.250     |
| MIROC6        | MIROC    | 日本 | 1.406     | 1.406     |
| TaiESM1       | RCEC     | 中国 | 1.250     | 0.938     |

2 多模式集成方法

2.1 集成方法

采用 6 种多模式集成方法,其中 3 种为统计学方法,分别为算术平均、权重平均和多元线性回归 [29];其他 3 种为机器学习算法,分别采用 BP 神经网络、LSTM 神经网络和 RF 模型。

2.1.1 BP 神经网络

BP 神经网络算法常用于解决分类、回归和预测等问题,网络包括输入层、隐含层和输出层 [30-31],其

中每个神经元在不同层之间相互连接,连接上带有权重值。BP 神经网络通过反向传播算法来训练网络,即先对网络进行前向传播计算,然后根据预测误差计算出各层神经元的误差梯度,并通过梯度下降法来更新权重值,从而提高神经网络的准确率。其基本结构如图 2 所示,  $x_i (1\leq i\leq n)$  为输入值,  $y$  为输出值,  $f_1, f_2$  为激活函数,  $w_{jk}, v_k (1\leq j\leq n, 1\leq k\leq m)$  为神经元之间的连接权重,  $h_k$  为隐含层第  $k$  个神经元的输入信号,  $b_k$  为隐含层输出信号,  $u$  为输出层的输入信号,  $\theta_k, \alpha$  为阈值。




图 2 BP 神经网络基本结构

Fig. 2 Basic structure of BP neural network

2.1.2 LSTM 神经网络

LSTM 神经网络是一种 RNN 的变体,具有强大的长短期记忆能力 [32],因此在自然语言处理、时间序列预测等领域得到广泛应用。LSTM 神经网络通过引入 3 个门控制器(输入门、遗忘门和输出门)来控制信息的流动从而有效解决了梯度消失的问题,提高了模型的表现力和训练效率 [33]。其基本结构如图 3 所示,  $\tanh$  为双曲正切激活函数,  $\sigma$  为 sigmoid 激活函数,  $\oplus$  和  $\odot$  分别表示向量之间的加法和点乘运算,  $S_t$  和  $C_t$  分别为  $t$  时刻的短期记忆和长期记忆,  $X_t$  为  $t$  时刻的输入数据,  $p_t$  为  $t$  时刻隐藏层状态。




图 3 LSTM 神经网络基本结构

Fig. 3 Basic structure of LSTM neural network

2.1.3 RF 模型

RF 模型是一种集成学习方法,由多个决策树组成的集合模型 [34-35]。RF 模型中的每个决策树对每个输入样本都会进行预测,最终的结果是所有决策

树预测结果的平均值(回归问题)或多数表决(分类问题)。由于 RF 模型采用了多个决策树的集成,具有较好的准确性、泛化能力和抗噪能力,被广泛应用于机器学习领域中的分类和回归等问题中,其原理如图 4 所示。




图 4 RF 模型原理

Fig. 4 Principle of RF model

2.2 降水

为了使集成结果更准确,在集成之前需要对每个模式进行偏差校正。本文采用的偏差校正方法为 Delta 方法<sup>[36]</sup>,Delta 方法假设基准期 GCMs 与观测值之间的偏差关系在预估期保持不变,即降水采用相对变化率,气温采用绝对变化量。图 5 为基准期 6 种集成方法模拟的降水量,可见,率定期 6 种集成方法降水量变化趋势基本与观测值一致,且绝大多数月份模拟值与观测值很贴合,但部分年份的月降水极值和夏季降水量变化情况模拟效果不理想,如 2003 年、2012 年等,可能是降水时空分布的不确定性

和各气候模式降水数据本身的不足所导致的。将 6 种集成方法的降水量模拟值与观测值进行对比分析,结果见表 2。黄河流域水源涵养区率定期多年平均降水量观测值为 511.37 mm,验证期为 551.86 mm。率定期 6 种集成方法的相对误差均较小,相关系数都在 0.9 以上,且纳什效率系数都在 0.8 及以上,3 种机器学习方法表现相对更加出色,尤其是 RF 模型。而验证期 6 种集成方法的降水量模拟值都存在不同程度的低估,且相对误差比较大,BP 神经网络的误差相对最小,LSTM 神经网络次之。从相关系数和纳什效率系数来看,BP 神经网络和 LSTM 神经网络表现较好,且 LSTM 神经网络最好。相对于率定期,验证期 RF 模型的模拟性能大幅度下降。

2.3 气温

图 6 为基准期 6 种集成方法气温模拟情况。可见,率定期 6 种集成方法的模拟效果都很好,绝大多数月份气温模拟值与观测值几乎相等,变化趋势完全一致;但验证期冬季气温的模拟偏差相对其他季节较大,最大月平均气温差值约为 5℃。综合比较,LSTM 神经网络集成方法的模拟值与观测值曲线更加贴合,模拟效果相对更好。

将 6 种集成方法的气温模拟值与观测值进行对比分析,结果见表 3。黄河流域水源涵养区率定期多年平均气温观测值为 1.61℃,验证期为 2.29℃。可以看出,无论是率定期还是验证期,6 种集成方法




图 5 基准期 6 种集成方法模拟的降水量

Fig. 5 Precipitation simulation by six integration methods during baseline period

表 2 6 种集成方法降水量模拟值与观测值对比分析结果

Table 2 Comparison and analysis results of simulated and observed precipitation values for six integration methods

| 集成方法      | 多年平均降水量/mm |        | 相对误差/% |         | 相关系数  |       | 纳什效率系数 |       |
|-----------|------------|--------|--------|---------|-------|-------|--------|-------|
|           | 率定期        | 验证期    | 率定期    | 验证期     | 率定期   | 验证期   | 率定期    | 验证期   |
| 算术平均      | 501.25     | 494.52 | -1.978 | -10.391 | 0.908 | 0.867 | 0.800  | 0.698 |
| 权重平均      | 515.80     | 501.48 | 0.867  | -9.130  | 0.904 | 0.874 | 0.809  | 0.725 |
| 多元线性回归    | 512.18     | 514.70 | 0.159  | -6.733  | 0.913 | 0.868 | 0.833  | 0.745 |
| BP 神经网络   | 524.81     | 541.88 | 2.629  | -1.808  | 0.938 | 0.908 | 0.878  | 0.816 |
| LSTM 神经网络 | 512.13     | 533.73 | 0.149  | -3.284  | 0.950 | 0.925 | 0.903  | 0.853 |
| RF 模型     | 509.82     | 501.43 | -0.303 | -9.139  | 0.989 | 0.883 | 0.976  | 0.761 |




图 6 基准期 6 种集成方法气温模拟情况

Fig. 6 Temperature simulation by six integration methods during baseline period

表 3 6 种集成方法气温模拟值与观测值对比分析结果

| 集成方法      | 多年平均气温/℃ |      | 绝对误差/℃ |       | 相关系数  |       | 纳什效率系数 |       |
|-----------|----------|------|--------|-------|-------|-------|--------|-------|
|           | 率定期      | 验证期  | 率定期    | 验证期   | 率定期   | 验证期   | 率定期    | 验证期   |
| 算术平均      | 0.48     | 0.93 | -1.13  | -1.36 | 0.989 | 0.986 | 0.935  | 0.924 |
| 权重平均      | 0.48     | 0.97 | -1.13  | -1.32 | 0.988 | 0.985 | 0.933  | 0.925 |
| 多元线性回归    | 1.61     | 1.99 | 0      | -0.31 | 0.990 | 0.988 | 0.980  | 0.975 |
| BP 神经网络   | 1.51     | 2.00 | -0.10  | -0.30 | 0.992 | 0.987 | 0.984  | 0.971 |
| LSTM 神经网络 | 1.61     | 2.03 | 0      | -0.26 | 0.995 | 0.993 | 0.989  | 0.984 |
| RF 模型     | 1.59     | 1.95 | -0.02  | -0.34 | 0.995 | 0.988 | 0.991  | 0.974 |

的相关系数都接近 1,LSTM 神经网络的相关系数都是最大。从绝对误差和纳什效率系数来看,3 种机器学习集成方法表现都很好,LSTM 神经网络最好。

综合降水和气温的模拟结果来看,3 种机器学习算法的多模式集成效果优于传统统计学方法。Wang 等<sup>[37]</sup>比较了 RF 模型、SVM、贝叶斯模式平均和算术平均 4 种多模式集成方法对澳大利亚气温和降雨的模拟能力,结果表明,RF 模型和 SVM 的表现比贝叶斯模式平均和算术平均更出色,这与本文的研究结论一致。机器学习算法在处理非线性复杂关系方面具有优势,其中 LSTM 神经网络拥有长短期记忆能力,能够更好地处理长序列数据,有效地避免了 BP 神经网络在训练过程中的梯度消失和过拟合问题。而 RF 则是由多个决策树组成,每个决策树只能捕捉局部规律,更适合处理结构化数据,对于长序列数据的处理能力相对较弱,所以 LSTM 神经网络在处理长序列和大量数据时能更好地捕捉数据中的变化趋势,这一点也被众多学者认可<sup>[38-39]</sup>。然而,多模式集成方法对于气温和降水的极值预估尚有不足之处,比较容易均化模式数据,对极端事件预报能力有限<sup>[30]</sup>,因此对降水和气温的极值预估性能和适用性还有待进一步验证。

### 3 基于 LSTM 神经网络多模式集成方法的未来降水和气温预估

为了进一步分析未来气候变化下的降水和气温

的变化趋势,将预估期分为 3 个时段,即近期(2026—2045 年)、中期(2046—2065 年)和远期(2066—2085 年),采用基准期模拟效果最好的 LSTM 神经网络多模式集成方法对未来 3 种气候变化情景下的 3 个时段降水和气温进行预估。

#### 3.1 未来降水和气温的变化趋势预估

图 7 为研究区基准期降水量观测值及不同情景下 LSTM 神经网络集成方法降水量预估值,图中阴影部分表示各情景下预估值最值的 95% 置信区间,表 4 为 LSTM 神经网络集成方法多年平均降水量预估值及线性趋势。由图 7 和表 4 可见,基准期年降水量分布在 420 ~ 630 mm 之间,多年平均降水量为 518.1 mm,且 1985—2002 年和 2003—2014 年两个时间段的年降水量分布差异较明显。3 种情景下、3 个未来时段的多年平均降水量基本上都高于基准期,但变化较小,分布在 514.5 ~ 540 mm 之间。在 SSP1-2.6 情景下,年降水量基本分布在 440 ~ 620 mm 之间,3 个未来时段的年降水量峰值都出现在各时段初期,如近期的 2026 年和 2030 年、中期的 2049 年及远期的 2067 年,而末期相对偏小,所以各时段的年降水量变化速率均为负数。在 SSP2-4.5 情景下,只有近期降水量呈增长趋势,远期下降趋势较明显,除 2046 年降水量接近 640 mm 外,其他年份都低于 600 mm。在 SSP5-8.5 情景下,近期和中期降水量呈增长趋势,远期降水量下降趋势较为明显,年降水量基本上分布在 450 ~ 600 mm 之间。图 7 中阴

表 4 LSTM 神经网络集成方法多年平均降水量预估值及线性趋势

Table 4 Estimated annual average precipitation and linear trends of LSTM neural network integration method

| 未来时段 | 多年平均降水量/mm |          |          | 线性趋势/(mm/a) |          |          |
|------|------------|----------|----------|-------------|----------|----------|
|      | SSP1-2.6   | SSP2-4.5 | SSP5-8.5 | SSP1-2.6    | SSP2-4.5 | SSP5-8.5 |
| 近期   | 524.2      | 514.5    | 530.8    | -1.478      | 0.858    | 1.327    |
| 中期   | 526.8      | 538.6    | 526.5    | -1.788      | -0.801   | 1.266    |
| 远期   | 528.4      | 527.7    | 532.0    | -1.533      | -2.637   | -2.762   |
| 预估期  | 526.5      | 527.0    | 529.8    | -0.084      | 0.198    | 0.021    |

影部分表示降水量预估中的不确定性,总体来说,3 种情景降水量的不确定性相差不大,3 个时段中均表现为中远期大于近期。

图 8 为研究区基准期气温观测值及不同情景下 LSTM 神经网络集成方法气温预估值,表 5 为 LSTM 神经网络集成模式多年平均气温预估值及线性趋势。由图 8 和表 5 可见,基准期年平均气温分布在 0.5 ~ 2.7 ℃ 之间,多年平均气温为 1.72 ℃,1985—1997 年和 1998—2014 年两个时间段的年平均气温分布差异较明显。3 种情景下、3 个未来时段的多年平均气温都高于基准期,但变化差异较大。在 SSP1-2.6 情景下,平均气温基本分布在 2.5 ~ 3.5 ℃ 之间,从线性趋势上看,3 个未来时段的气温变化都比较平稳。在 SSP2-4.5 情景下,年平均气温

分布在 2.4 ~ 4.3 ℃,近期气温变化比较平稳,中期增温幅度最大,远期也有一定的增长。在 SSP5-8.5 情景下,年平均气温分布在 2.6 ~ 5.6 ℃,从近期到远期,气温增幅越来越大。图 8 中的阴影部分表明,3 种情景中 SSP1-2.6 不确定性最小,SSP2-4.5 次之,SSP5-8.5 最大;3 个时段中近、中、远期不确定性逐渐增大,且差异较明显,相比较降水而言,气温预估的不确定性相对较小。

表 5 LSTM 神经网络集成方法多年平均气温预估值及线性趋势

Table 5 Estimated annual average temperature and linear trends of LSTM neural network integration method

| 未来时段 | 多年平均气温/℃ |          |          | 线性趋势/(℃/a) |          |          |
|------|----------|----------|----------|------------|----------|----------|
|      | SSP1-2.6 | SSP2-4.5 | SSP5-8.5 | SSP1-2.6   | SSP2-4.5 | SSP5-8.5 |
| 近期   | 2.79     | 2.84     | 2.98     | -0.002     | -0.004   | 0.021    |
| 中期   | 3.12     | 3.31     | 3.94     | -0.005     | 0.026    | 0.051    |
| 远期   | 3.10     | 3.74     | 4.84     | 0.011      | 0.012    | 0.067    |
| 预估期  | 3.00     | 3.30     | 3.92     | 0.007      | 0.021    | 0.047    |

3.2 未来降水和气温的季节变化

图 9 为不同季节基准期降水量及 LSTM 神经网络集成方法预估降水量变化率。由图 9 可见,不同季节基准期降水量由大到小依次为夏季、秋季、春季、冬季。在春季,未来 3 个时段,3 种情景下的降水量都在增加,其中,SSP5-8.5 情景增幅最大,SSP2-




图 7 研究区基准期降水量观测值及不同情景下 LSTM 神经网络集成方法降水量预估值

Fig. 7 Observations of precipitation during baseline period and estimation of precipitation using LSTM neural network integration method under different scenarios in research area




图 8 研究区基准期气温观测值及不同情景下 LSTM 神经网络集成方法气温预估值

Fig. 8 Observations of temperature during baseline period and estimation of temperature using LSTM neural network integration method under different scenarios in research area




图9 不同季节基准期降水量及 LSTM 神经网络集成方法预估降水量变化率

Fig.9 Precipitation during baseline period and estimation of precipitation changing rate using LSTM neural network integration method in different seasons

4.5 最小,相对于近期,中、远期 3 种情景降水量增幅都有不同程度的扩大。在夏季,除了近期 SSP1-2.6 情景的降水量略有减少外,未来所有时段的不同情景下降水量都在增加,其中 SSP2-4.5 增幅最大,SSP1-2.6 情景从近期到远期的降水量不断增加。在秋季,SSP1-2.6 情景下的近期降水量增加约 8%,中远期略有减少;SSP2-4.5 情景下的近期降水量减少约 8.5%,中期增加约 3%,远期减少 4%;SSP5-8.5 情景下的近期降水量增加约 4.5%,中期减少约 10.5%,远期减少约 4%。冬季降水量都在减少,3 种情景中,近期和中期 SSP1-2.6 情景下的降水量减少最多,远期 SSP2-4.5 情景下减少最多,由于冬季降水量较少,所以降水量变化率相对于其他季节较大。

进一步探究未来不同情景、不同时段 of LSTM 神经网络集成方法预估降水量的不确定性变化,图 9 中误差棒为预估降水量相对于基准期降水量变化率的 95% 置信区间,反映了降水量变化率的不确定性。由图 9(b)(c)(d) 可见,3 个时段秋冬季降水量变化率的不确定性明显大于春夏季。除近期夏季的 SSP1-2.6 情景外,总体上,3 种情景下、3 个时段春夏季不确定性相差不大;在秋冬季,近期 SSP5-8.5 情景不确定性略小于其他两种情景,而中远期 SSP5-8.5 情景相对更大,不同时段 SSP1-2.6 和 SSP2-4.5 情景的不确定性变幅不大,SSP5-8.5 情景的不确定性一直增加。

图 10 为不同季节基准期气温及 LSTM 神经网络

集成方法预估气温变化量。由图 10 可见,基准期气温年内分布为夏季最高,冬季最低。未来 3 种情景下的四季气温都在增加,总体上,从近期到远期的气温增幅越来越大,尤其是 SSP5-8.5 情景。在春季,近期 3 种情景下的气温增幅接近 (1.4 ~ 1.5 °C),中远期差异越来越大,SSP5-8.5 情景下的增温速度最快,远期增温 2.8 ~ 2.9 °C。在夏季和秋季,SSP2-4.5 和 SSP5-8.5 情景下的增温速度比较快,尤其是中远期的秋季增温幅度最大,SSP2-4.5 情景下从近期的增温约 1.1 °C 到远期约 2.3 °C,SSP5-8.5 情景下从近期增温约 1.4 °C 到远期约 4.0 °C。在冬季,近期 3 种情景下的增温幅度相近 (0.6 ~ 0.7 °C),中期 SSP1-2.6 和 SSP2-4.5 情景下的增温都为 1.0 °C,SSP5-8.5 增温达 1.7 °C,远期 SSP2-4.5 和 SSP5-8.5 情景下的增温幅度都有不同程度的继续增加,但 SSP1-2.6 情景下远期的增温比中期低 0.2 °C。

进一步探究未来不同情景、不同时段 of LSTM 神经网络集成方法预估气温的不确定性变化,由图 10(b)(c)(d) 可见,未来时段夏季气温变化不确定性相对最小,冬季最大。在春季,近、中期 SSP2-4.5 情景不确定性最大,远期 SSP5-8.5 最大;夏季 3 种情景不确定性都较小,中、远期 SSP5-8.5 情景相对更大;秋季近、中期 3 种情景不确定性基本相同,远期 SSP5-8.5 情景相对更大;冬季近期 SSP2-4.5 情景不确定性最大,中期为 SSP1-2.6,远期为 SSP2-4.5,且总体上远期 3 种情景不确定性要大于近、中期。




图 10 不同季节基准期气温及 LSTM 神经网络集成方法预估气温变化量

Fig. 10 Temperature during baseline period and estimation of temperature change using LSTM neural network integration method in different seasons

## 4 结 论

a. 构建了算术平均、权重平均、多元线性回归、BP 神经网络、LSTM 神经网络和 RF 等 6 种多模式集成方法,基于黄河流域水源涵养区历史降水量和气温数据,评估不同集成方法的模拟效果。多模式集成方法能很好地再现基准期降水量和气温变化,3 种机器学习方法表现相对更好,LSTM 神经网络集成方法效果最好。

b. 采用 LSTM 神经网络多模式集成方法对未来降水量和气温进行预估。相对于基准期,3 种气候情景下的多年平均降水量和春夏季降水量基本上都有所增加,秋季有增有减,冬季都在减少;在 SSP1-2.6 情景下,各时段的年降水量峰值都出现在各时段初期,在 SSP2-4.5 和 SSP5-8.5 情景下,近期年降水量呈增长趋势,远期下降趋势较明显。3 种情景下的气温都呈上升趋势,气温增幅由小到大依次为 SSP1-2.6 情景、SSP2-4.5 情景、SSP5-8.5 情景,秋季气温增幅最大,冬季最小。

c. 3 种情景下降水量变化率的不确定性相近,均表现为中、远期大于近期,季节上秋冬季不确定性明显大于春夏季。气温变化的不确定性则是 SSP1-2.6 情景最小,SSP2-4.5 次之,SSP5-8.5 最大,预估期 3 个时段中,近、中、远期不确定性依次增大,夏季气温变化的不确定性相对最小,冬季最大。

## 参考文献:

[ 1 ] 付晓花,董增川,韩锐,等. 复杂河网地区气候-水文-水

动力耦合模型模拟[J]. 水资源保护,2023,39(3):162-169. (FU Xiaohua, DONG Zengchuan, HAN Rui, et al. Simulation of climate-hydrologic-hydrodynamic coupling model in complex river network area[J]. Water Resources Protection,2023,39(3):162-169. (in Chinese))

[ 2 ] 万幸如,程超源,白德凤,等. 气候变化的生态影响及适应对策[J]. 中国科学院院刊,2023,38(3):518-527. (WAN Xinru, CHENG Chaoyuan, BAI Defeng, et al. Ecological impacts of climate change and adaption strategies[J]. Bulletin of Chinese Academy of Sciences, 2023,38(3):518-527. (in Chinese))

[ 3 ] 李纯,姜彤,王艳君,等. 基于 CMIP6 模式的黄河上游地区未来气温模拟预估[J]. 冰川冻土,2022,44(1):171-178. (LI Chun, JIANG Tong, WANG Yanjun, et al. Simulation and estimation of future air temperature in upper basin of the Yellow River based on CMIP6 models [J]. Journal of Glaciology and Geocryology,2022,44(1): 171-178. (in Chinese))

[ 4 ] 何旭,缪子梅,田佳西,等. 基于 CMIP 6 多模式的长江流域气温、降水与径流预估[J]. 南京林业大学学报 (自然科学版), 2024, 48(2): 1-8. (HE Xu, MIAO Zimei, TIAN Jiayi, et al. Temperature, precipitation and runoff prediction in the Yangtze River Basin based on CMIP 6 multi-model [J]. Journal of Nanjing Forestry University (Natural Science Edition), 2024, 48(2): 1-8. (in Chinese))

[ 5 ] DEY A, SAHOO D P, KUMAR R, et al. A multimodel ensemble machine learning approach for CMIP6 climate model projections in an Indian River Basin [J]. International Journal of Climatology,2022,42(16):9215-9236.

- [ 6 ] 张晓璐,王晓欣,华丽娟,等. 新疆温度和降水变化的CMIP6 模式预估[J]. 大气科学,2023,47(2):387-398. ( ZHANG Xiaolu, WANG Xiaoxin, HUA Lijuan, et al. Projections of temperature and precipitation over Xinjiang based on CMIP6 models [ J ]. Chinese Journal of Atmospheric Sciences, 2023, 47 ( 2 ): 387-398. ( in Chinese ) )
- [ 7 ] 鞠琴,郝振纯,余钟波,等. IPCC AR4 气候情景下长江流域径流预测[J]. 水科学进展,2011,22(4):462-469. ( JU Qin, HAO Zhenchun, YU Zhongbo, et al. Runoff prediction in the Yangtze River Basin based on IPCC AR4 climate change scenarios [ J ]. Advance in Water Science, 2011, 22(4):462-469. ( in Chinese ) )
- [ 8 ] 胡义明,罗序义,梁忠民,等. 基于藤 Copula 多维联合分布的CMIP5 多模式降雨综合方法研究[J]. 中国农村水利水电,2021(4):10-15. ( HU Yiming, LUO Xuyi, LIANG Zhongmin, et al. Research on CMIP5 multi-model precipitation synthesis method based on vine copula multivariate joint probability distribution [ J ]. China Rural Water and Hydropower, 2021(4):10-15. ( in Chinese ) )
- [ 9 ] 李晓蕾,王卫光,张淑林. 基于CMIP6 多模式的长江流域未来降水变化趋势分析[J]. 中国农村水利水电,2022(3):1-7. ( LI Xiaolei, WANG Weiguang, ZHANG Shulin. A trend analysis of future precipitation in the Yangtze River Basin based on CMIP6 multi-model [ J ]. China Rural Water and Hydropower, 2022(3):1-7. ( in Chinese ) )
- [ 10 ] 吴金雨,鞠琴,刘小妮,等. CMIP6 模式对黄河水源涵养区降水和气温模拟能力的评估[J]. 水利水运工程学报,2023(6):1-12. ( WU Jinyu, JU Qin, LIU Xiaoni, et al. Assessment of precipitation and temperature in the water conservation region of the Yellow River Basin using CMIP6 models [ J ]. Hydro-Science and Engineering, 2023(6):1-12. ( in Chinese ) )
- [ 11 ] KRISHNAMURTI T N, KISHTAWAL C M, LAROW T E. Improved weather and seasonal climate forecasts from multi-model superensemble [ J ]. Science, 1999, 285 ( 5433 ): 1548-1550.
- [ 12 ] 狄靖月,赵琳娜,张国平,等. 降水集合预报集成方法研究[J]. 气象,2013,39(6):8. ( DI Jingyue, ZHAO Linna, ZHANG Guoping, et al. Study on precipitation multimodel super ensemble forecast technique [ J ]. Meteorological Journal, 2013, 39(6):8. ( in Chinese ) )
- [ 13 ] 智协飞,赵忱. 基于集合成员订正的强降水多模式集成预报[J]. 应用气象学报,2020,31(3):12. ( ZHI Xiefei, ZHAO Chen. Heavy precipitation forecasts based on multi-model ensemble members [ J ]. Journal of Applied Meteorological Science, 2020, 31(3):12. ( in Chinese ) )
- [ 14 ] 李芳. 基于多模式集合方案的中国东部夏季降水概率季度预测[J]. 气象学报,2012,70(2):183-191. ( LI Fang. Probabilistic seasonal prediction of summer rainfall over East China based on multi-model ensemble schemes [ J ]. Acta Meteorological Sinica, 2012, 70 ( 2 ): 183-191. ( in Chinese ) )
- [ 15 ] 周梦瑶,袁飞,江善虎,等. 基于贝叶斯模型平均的赣江与汉江流域多气候模式集合研究[J]. 水电能源科学,2021,39(9):1-5. ( ZHOU Mengyao, YUAN Fei, JIANG Shanhu, et al. Multi-climate model ensemble in Ganjiang and Hanjiang Basins based on Bayesian model average [ J ]. Water Resources and Power, 2021, 39(9):1-5. ( in Chinese ) )
- [ 16 ] 马阳,崔洋,张雯,等. 基于CMIP6 模式的黄河流域宁夏段未来气温变化预估研究[J]. 干旱气象,2023,41(1):43-53. ( MA Yang, CUI Yang, ZHANG Wen, et al. Projection of the future temperature changes of Yellow River Basin Ningxia section based on CMIP6 models [ J ]. Journal of Arid Meteorology, 2023, 41 ( 1 ): 43-53. ( in Chinese ) )
- [ 17 ] 贺圣平,王会军,李华,等. 机器学习的原理及其在气候预测中的潜在应用[J]. 大气科学学报,2021,44(1):26-38. ( HE Shengping, WANG Huijun, LI Hua, et al. Machine learning and its potential application to climate prediction [ J ]. Transactions Atmospheric Sciences, 2021, 44(1):26-38. ( in Chinese ) )
- [ 18 ] 金浩宇,鞠琴,曲珍,等. 基于集成方法的长江源区未来气候变化预测研究[J]. 水力发电,2019,45(11):9-13. ( JIN Haoyu, JU Qin, QU Zhen, et al. Future climate change prediction in the source region of Yangtze River based on integrated method [ J ]. Journal of Hydroelectric Engineering, 2019, 45(11):9-13. ( in Chinese ) )
- [ 19 ] 常晓敏,李攀登,魏科宇,等. 基于多模式集成输出天气变量的参考作物腾发量预报[J]. 农业工程学报,2023,39(5):79-89. ( CHANG Xiaomin, LI Pandeng, WEI Keyu, et al. Reference crop evapotranspiration forecast using multi-model integrated output weather variables [ J ]. Transactions of the Chinese Society of Agricultural Engineering, 2023, 39(5):79-89. ( in Chinese ) )
- [ 20 ] WEYN J A, DURRAN D R, CARUANA R. Can machines learn to predict weather? using deep learning to predict gridded 500-hpa geopotential height from historical weather data [ J ]. Journal of Advances in Modeling Earth Systems, 2019, 11(8):2680-2693.
- [ 21 ] 李原园,李云玲,王慧杰,等. 强化黄河流域水资源调控思路与对策[J]. 中国水利,2021(18):9-10. ( LI Yuanyuan, LI Yunling, WANG Huijie, et al. Thoughts and proactive measures for strengthening water resources regulation in the Yellow River Basin [ J ]. China Water Resources, 2021(18):9-10. ( in Chinese ) )
- [ 22 ] 王国庆. 黄河流域水源涵养区界定[J]. 水文,2022,42(2):65. ( WANG Guoqing. Definition of water conservation areas in the Yellow River Basin [ J ]. Journal of China Hydrology, 2022, 42(2):65. ( in Chinese ) )

- [23] 周冰玉,李志威,田世民,等. 黄河源区水源涵养能力研究综述[J]. 水利水电科技进展,2022,42(4):87-93. (ZHOU Bingyu, LI Zhiwei, TIAN Shimin, et al. A review on water conservation capacity in Yellow River source region[J]. Advances in Science and Technology of Water Resources,2022,42(4):87-93. (in Chinese))
- [24] 魏伊宁,李勋贵,李芳. 黄河上游径流丰枯空间分布特征及其影响因素[J]. 水资源保护,2021,37(6):103-113. (WEI Yining, LI Xungui, LI Fang. Spatial distribution characteristics and influencing factors of wet and dry of runoff in upper reaches of the Yellow River [J]. Water Resources Protection,2021,37(6):103-113. (in Chinese))
- [25] 张丽霞,陈晓龙,辛晓歌. CMIP6 情景模式比较计划 (ScenarioMIP) 概况与评述[J]. 气候变化研究进展,2019,15(5):519-525. (ZHANG Lixia, CHEN Xiaolong, XIN Xiaoge. Short commentary on CMIP6 Scenario Model Intercomparison Project (ScenarioMIP) [J]. Climate Change Research,2019,15(5):519-525. (in Chinese))
- [26] HE J, YANG K, TANG W J, et al. The first high-resolution meteorological forcing dataset for land process studies over China[J]. Scientific Data,2020,7:25.
- [27] YANG K, HE J, TANG W J, et al. On downward shortwave and longwave radiations over high altitude regions: observation and modeling in the Tibetan Plateau [J]. Agricultural and Forest Meteorology, 2010, 150 (1): 38-46.
- [28] 饶莉娟,王健林,张星. 不同插值方法对精细化预报产品在青岛地区的检验比较[J]. 中国农学通报,2020,36(32):100-108. (RAO Lijuan, WANG Jianlin, ZHANG Xing. Different interpolation methods: comparison for refined forecast products in Qingdao area [J]. Chinese Agricultural Science Bulletin,2020,36(32):100-108. (in Chinese))
- [29] 周海,秦昊,吉璐莹,等. 地面气象要素多模式集成预报研究进展[J]. 大气科学学报,2022,45(6):11. (ZHOU Hai, QIN Hao, JI Luying, et al. Research progresses of multimodel ensemble forecast of surface meteorological elements [J]. Transactions Atmospheric Sciences,2022,45(6):11. (in Chinese))
- [30] 朱诚,王昭敏,隆锋,等. 基于 ABC-BP 神经网络的地铁盾构地表沉降预测[J]. 河海大学学报(自然科学版),2023,51(4):72-80. (ZHU Cheng, WANG Zhaomin, LONG Feng, et al. Prediction of ground settlement of subway shield based on ABC-BP neural network [J]. Journal of Hohai University (Natural Sciences),2023,51(4):72-80. (in Chinese))
- [31] JU Q, YU Z, HAO Z, et al. Division-based rainfall-runoff simulations with BP neural networks and Xinanjiang model [J]. Neurocomputing,2009,72(13-15):2873-2883.
- [32] 王贝,陈浩,何锡君,等. 基于 LSTM 深度学习的河湖生态流量预警预报模型研究[J]. 水文,2023,43(3):1-6. (WANG Bei, CHEN Hao, HE Xijun, et al. Study on early warning and forecasting model of ecological flow in rivers and lakes based on LSTM deep learning [J]. Journal of China Hydrology,2023,43(3):1-6. (in Chinese))
- [33] 牛欣怡,鲁程鹏,卢佳赟,等. 机器学习模型在地下水埋深模拟中的适应性分析[J]. 河海大学学报(自然科学版),2022,50(4):74-82. (NIU Xinyi, LU Chengpeng, LU Jiayun, et al. Adaptability analysis of machine learning model in groundwater depth simulation [J]. Journal of Hohai University (Natural Sciences),2022,50(4):74-82. (in Chinese))
- [34] 欧斌,吴邦彬,袁杰,等. 基于 LSTM 的混凝土坝变形预测模型[J]. 水利水电科技进展,2022,42(1):21-26. (OU Bin, WU Bangbin, YUAN Jie, et al. LSTM-based deformation prediction model of concrete dams [J]. Advances in Science and Technology of Water Resources,2022,42(1):21-26. (in Chinese))
- [35] 高玮志,高华勇,王兆礼,等. 基于机器学习的太湖流域多层次防洪调度方案综合评价[J]. 水资源保护,2023,39(3):118-125. (GAO Weizhi, GAO Huayong, WANG Zhaoli, et al. Comprehensive evaluation of multi-level flood control operation schemes in the Taihu Lake Basin based on machine learning [J]. Water Resources Protection,2023,39(3):118-125. (in Chinese))
- [36] 杜懿. 基于统计降尺度的东江流域未来气候预估[J]. 人民珠江,2023,44(3):40-50. (DU Yi. Study on climate projection of Dongjiang River basin based on downscaling methods [J]. Pearl River,2023,44(3):40-50. (in Chinese))
- [37] WANG B, ZHENG L, LIU D L, et al. Using multi-model ensembles of CMIP5 global climate models to reproduce observed monthly rainfall and temperature with machine learning methods in Australia[J]. International Journal of Climatology,2018,38(13):4891-4902.
- [38] 刘新,赵宁,郭金运,等. 基于 LSTM 神经网络的青藏高原月降水量预测[J]. 地球信息科学学报,2020,22(8):1617-1629. (LIU Xin, ZHAO Ning, GUO Jinyun, et al. Prediction of monthly precipitation over the Tibetan Plateau based on LSTM neural network [J]. Journal of Geo-Information Science,2020,22(8):1617-1629. (in Chinese))
- [39] 李步,田富强,李钰坤,等. 融合气象要素时空特征的深度学习水文模型[J]. 水科学进展,2022,33(6):904-913. (LI Bu, TIAN Fuqiang, LI Yukun, et al. Development of a spatiotemporal deep-learning-based hydrological model[J]. Advance in Water Science,2022,33(6):904-913. (in Chinese))

(收稿日期:2023-06-29 编辑:王芳)