

ZHAO Haijuan, SUN Feifei, LIU Dandan, ZHANG Qiang, GUO Jianguang, XIE Jinping, LI Jianzhu. Monthly Precipitation Forecast in Shaoyang Region Based on Sunspots (in Chinese). *Chinese Journal of Space Science*, 2026, 46(5): 1–13. CSTR:32142.14.cjss.2025–0220. DOI:10.11728/cjss2026.05.2025–0220

基于太阳黑子的邵阳地区月降水量预报*

赵海娟^{1,2,3} 孙飞飞⁴ 刘丹丹^{1,2,3} 张强⁵
郭建广^{1,2,3} 谢津平⁴ 李建柱⁶

1(国家卫星气象中心(国家空间天气监测预警中心) 北京 100081)

2(许健民气象卫星创新中心 北京 100081)

3(中国气象局空间天气重点实验室 北京 100081)

4(中水北方勘测设计研究有限责任公司 天津 300222)

5(天津市水文水资源管理中心 天津 300211)

6(天津大学建筑工程学院 天津 300072)

摘要 开展邵阳地区月降水量的精准预报研究, 构建太阳黑子相对数年滑月均值 (R_{SSNy}) 指数, 基于该指数构建径向基函数 (RBF) 神经网络预报模型; 以 R_{SSNy} 指数的预测结果为核心输入变量, 构建多层感知器 (MLP) 月降水量预报模型, 实现从太阳活动信号到降水量的关联建模; 定义降水量丰枯指数 (RAI), 通过该指数的构建有效克服预报模型优化过程中局部最优与全局最优的矛盾, 进而采用 MLP 模型开展 RAI 预测研究. 研究表明, 基于 R_{SSNy} 指数的 RBF 预报模型性能优异, 在率定期、验证期及预测期均呈现良好的稳定性与精度, 其中 $t+1$ 月预测结果中, 93% 样本的相对误差小于 10%; MLP 月降水量预报模型拟合与泛化能力突出, 训练集与测试集的决定系数 (R^2) 均达到 0.99, 满足高精度预报要求; 定义的 RAI 指数为降水量丰枯状态的量化评估提供了有效工具, 具有进一步深化研究与推广应用的价值; MLP 月 RAI 预报模型的预测精度达到满足相关规范规定的精度标准要求, 可有效实现降水量丰枯状态的提前预判. 综上研究结果, 突破了传统降水预报仅依赖局地气象因子的局限, 为月尺度降水预报提供了新的技术路径与理论支撑.

关键词 太阳黑子数, R_{SSNy} 指数, 月降水量, 预报模型, 降水量丰枯指数

中图分类号 P456.9

Monthly Precipitation Forecast in Shaoyang Region Based on Sunspots

ZHAO Haijuan^{1,2,3} SUN Feifei⁴ LIU Dandan^{1,2,3} ZHANG Qiang⁵
GUO Jianguang^{1,2,3} XIE Jinping⁴ LI Jianzhu⁶

* 中国气象局“空间天气监测与预警”重点创新团队项目 (CMA2024ZD01) 和天津市 2024 年中央引导地方科技发展基金项目 (24ZYCGYS00730) 共同资助

2025-12-16 收到原稿, 2026-07-31 收到修定稿

©The Author(s) 2026. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

1(National Satellite Meteorological Center (National Center for Space Weather),
China Meteorological Administration, Beijing 100081)

2(Innovation Center for FengYun Meteorological Satellite (FYSIC), Beijing 100081)

3(Key Laboratory of Space Weather, CMA, Beijing 100081)

4(China Water Resources Beifang Investigation, Design and Research Co. Ltd., Tianjin 300222)

5(Tianjin Hydrological and Water Resources Management Center, Tianjin 300211)

6(School of Civil Engineering, Tianjin University, Tianjin 300072)

Abstract The prediction of monthly precipitation is of great significance for water resource utilization and water conservancy project scheduling. The core work of this study includes: proposing a new sunspot R_{SSNy} index and constructing an RBF forecasting model; construct a Multilayer-Perceptron (MLP) monthly precipitation forecast model based on the R_{SSNy} index prediction value; construct the Rainfall Abundance Index (RAI) to overcome the contradiction between local and global optima, and using MLP for RAI prediction. The results show that: the Radial Basis Function network (RBF) forecasting model of R_{SSNy} index performs well in the calibration, validation, and prediction stages, with a relative error of less than 10% for 93% of the predicted values in month $t+1$; the training and testing sets of the MLP monthly precipitation forecast model have good performance, with R^2 values of 0.99 for both sets; the defined RAI index provides an effective tool for the quantitative assessment of precipitation abundance and scarcity states, and holds value for further research deepening and application promotion; the MLP monthly RAI forecast model performs well and meets the accuracy requirements. The research on monthly precipitation forecast based on sunspots has pioneering significance.

Key words Sunspot number, R_{SSNy} index, Monthly precipitation, Forecasting model, Rainfall abundance index

0 引言

中长期降水预报是水资源优化利用、水旱灾害防御和水利工程调度的关键前提之一^[1-3]。然而, 中长期降水量受到多种自然因素和人为因素的影响, 例如太阳活动^[4]、气候变化^[5,6]等自然因素, 人为因素涵盖水库调度^[7]、跨区域引调水等人类活动的干扰。

已有大量观测证据表明, 年降水量与太阳黑子数存在显著的关联性^[4,5,8,9]。诸多研究成果^[4,5,8-18]进一步证实, 太阳活动对年降水量变化具有直接驱动作用。例如针对 1901—2020 年波兰邻近中欧区域 3 条河流的实测流量、降水及气温数据集, 相关研究采用小波变换方法开展分析, 明确了太阳活动强度与年径流量变化相关性的频率特征及时空分布规律, 同时揭示了太阳活动与年径流量之间存在显著的非线性关联^[18]; 而径流量与降水量存在密切的水文响应关系, 该研究结果亦间接佐证了太阳活动对降水过程存在潜在影响。

太阳黑子的周期性演变特征表明, 太阳活动与洪水、干旱等极端水文灾害之间存在显著的相关性^[4,19]。作为水文循环系统之外的天文驱动因子^[20], 太阳活动通过对全球气候系统产生周期性调制作用, 间接影响水文过程演变。大量研究结果表明, 总体上太阳活动或太阳辐射的变化确实能够影响地球的气候。基于观测与气候模式的模拟研究, 目前学界提出两种机制对此予以解释, 两种机制可叠加并相互增强, 使得区域对太阳辐射初始微小扰动的响应得到放大。第一种机制为自上向下机制, 即在峰值太阳年有更强的太阳紫外辐射 (UV), 直接通过增加辐射与间接通过 O_3 造成平流层增暖。进而引发影响热带深对流的一系列过程链。此外, 在太阳处于最小条件下, 热带平流层上部的加热比平均值小, 这减弱了赤道-极地温度梯度。该信号可向下传播, 减弱对流层中纬西风强度, 有利于北极涛动 (AO) 或 NAO 转为负位相。第二种机理为自下向上机制, 其涉及到热带和副热带太平洋的耦合海-气辐射过程。同样也影响热带内部地区的对流, 该机

制也被认为可在更长时间尺度上(年代—百年尺度)上影响区域温度,有助于解释古气候记录中的区域温度变化。但这种机制对全球或半球平均温度,无论在短期或长期时间尺度上几乎均无太大影响^[21,22]。与此同时,大气环流过程长期受下垫面自然地理特征的制约,不仅主导季节性气候分异,更为不同尺度天气系统的生成与演化提供了基础动力背景及随机扰动条件^[20]。

在前期研究中,研究团队已基于多层感知器(MLP)构建了年太阳黑子数与年降水量的关联模型,并将其应用于黄河流域万家寨水库流域,取得了理想的预报效果;同时,基于径向基函数神经网络(RBF)构建了太阳黑子数平滑月均值预报模型^[23],为月尺度太阳活动预测提供了技术支撑。

为进一步深化月尺度太阳活动与降水过程的关联机制研究,提升月降水量预报精度,本文重点从以下两方面开展研究工作:构建太阳黑子相对数年滑月均值 R_{SSNy} 指数,优化 $t+1$ 月太阳黑子指数的预报模型,提升短期太阳活动预测精度;在前期研究基础上,建立 R_{SSNy} 指数与月降水量的关联预报模型,并系统评估其 $t+1$ 月降水量的预报精度。

1 基于太阳黑子的月降水量预报方法

月径流预报问题可转化为以多层感知器(MLP)

模型为约束条件的粒子群优化(PSO)问题。本文提出一种基于太阳黑子数月径流量动态预报模型,具体流程如图1所示,分以下五个步骤实施。

步骤1 $t+1$ 月 R_{SSNy} 指数预测。以历史月尺度 R_{SSNy} 指数序列为输入数据集,通过预设预报模型计算得到 $t+1$ 月 R_{SSNy} 指数预测值,为后续月降水量关联建模提供核心驱动参数。

步骤2 R_{SSNy} 指数与月降水量的 MLP(Multi-layer-Perceptron) 关联模型构建。以实测月 R_{SSNy} 指数为输入变量、实测月降水量为输出变量,构建 MLP 神经网络模型,并完成参数率定与验证,建立月太阳黑子活动与月降水量之间的非线性映射关系。

步骤3 基于 PSO 算法的 $t+1$ 月降水量序列求解。以第二步构建的 MLP 关联模型为基础, $t+1$ 月 $SSNy$ 指数预测值作为输入,采用粒子群优化(PSO)算法开展寻优计算,求解得到 $t+1$ 月降水量序列对应的局部最优解与全局最优解。

步骤4 降水量丰枯指数(RAI)定义与序列构建。整合第三步获取的局部最优解、全局最优解及局部极大值,定义形成 RAI 指数序列;结合实测月降水量数据求解各历史月份的 RAI 指数序列。

步骤5 RAI 序列拟合与预报精度评估。利用 MLP 模型对 RAI 月值序列进行拟合训练,基于训练完成的模型实现 $t+1$ 月降水量预报;参照《水文情报预报规范》(GB/T 22482—2008)^[24] 中的精度评价标




图1 基于太阳黑子数的月降水量预报方法

Fig. 1 Framework of monthly precipitation forecasting method based on sunspot number

准, 对 $t+1$ 月降水量预测结果进行量化评估.

研究所用的月降水量数据为湖南省邵阳市 1960—2023 年的月降水量数据, 数据来源于北京师范大学地理科学学院 Hu 等^[25] 整理发布的 CHM_PRE V2 的日降水量数据. 以研究区中心点经纬度 (N27.22°, E111.24°) 为基准, 提取对应网格 1960—2023 年的日降水量数据, 经月度汇总处理后得到研究所需的月降水量时序数据集. 太阳黑子数的数据来源于国际互联网公开数据.

2 太阳黑子新指数预报

2.1 太阳黑子相对数年滑月均值

太阳黑子相对数平滑月均值 R_{SSNy} 是量化描述太阳活动强度与演化水平的核心指标, 因其能有效削弱短期随机扰动、凸显太阳活动的周期性特征, 被广泛应用于长期太阳活动相关参量的预报建模中, 作为核心输入变量支撑模型构建. 目前国际通用的是 13 个月太阳黑子相对数平滑月均值 (记为 SSN), 其中第 i 月的 SSN_i (记为 R_{SSNi}) 计算式为

$$R_{SSNi} = \frac{1}{12} \left(\frac{1}{2} (R_{SNi-6} + R_{SNi+6}) + R_{SNi-5} + R_{SNi-4} + \dots + R_{SNi+4} + R_{SNi+5} \right). \quad (1)$$

其中, R_{SNi} 为第 i 月太阳黑子相对数月均值, 其计算方式为对该自然月内每日太阳黑子相对数进行算术平均得到. 由上述计算方法可知, 13 个月太阳黑子相对数平滑月均值 (SSN) 的最新值获取存在 6 个月的时间延迟, 该特性使其在水文预报等业务化应用场景中存在明显局限性.

为解决传统 SSN 指数 6 个月时间延迟的核心问题, 本研究提出一种新型太阳活动水平量化指标——太阳黑子相对数年滑月均值 (记为 R_{SSNy}) 指数. 该指数在某一自然月结束后, 可直接通过预设公式完成计算并获取结果, 能够即时作为输入参数应用于各类相关预报模型, 有效规避了传统 SSN 指数的时间延迟缺陷, 进而显著提升预报模型的时效性能.

太阳黑子相对数年滑月均值的具体计算方法为^[26]

$$R_{SSNy} = \sum (R_{SNi-11} + R_{SNi-10} + \dots + R_{SNi-1} + R_{SNi}) / 12. \quad (2)$$

其中, R_{SNi} 为第 i 月的太阳黑子相对数月均值, R_{SNi-1} 为其前一个月的太阳黑子相对数月均值, 依次类推, R_{SNi-11} 为其前第 11 个月的太阳黑子相对数月均值.

2.2 采用 RBF 方法对 R_{SSNy} 进行预测

选取从 1750 年 1 月—1949 年 12 月的数据用径向基函数 (RBF) 网络进行训练, 用前三个月的观测值 $D(n-2)$, $D(n-1)$, $D(n)$ 作为网络的输入向量, 分别用其后第一个月和第二个月的观测值 $D(n+1)$ 和 $D(n+2)$ 作为输出向量对网络进行训练. 再选取 1950 年 1 月至 2025 年 2 月的数据进行预报试验, 用前三个月的观测值 $D(n-2)$, $D(n-1)$, $D(n)$ 作为网络的输入向量, 则输出向量即为未来第一个月和第二个月的预测值 $D(n+1)$ 和 $D(n+2)$. 采用 RBF (Radial Basis Function Network) 方法开展太阳黑子指数 $SSNy$ 预测方法的细节见参考文献^[23].

径向基函数 (RBF) 网络是以函数逼近理论为基础而构造的一类前向网络, 这类网络的学习等价于在多维空间中寻找训练数据的最佳拟合平面. 径向基函数网络的每个隐层神经元传递函数均构成拟合平面的基函数, 网络也由此得名^[27].

该网络避免了像 BP 网络那样烦琐冗长的计算, 具有较高的运算速度和外推能力, 同时, 网络有较强的非线性映射功能. RBF 网络通过非线性基函数的线性组合实现从输入空间 R^N 到输出空间 R^M 的非线性转换^[28]. 而太阳黑子数是非线性较强的时间序列, 对该序列进行预测, 即从前 N 个数据中预测出将来的 M 个数据, 实质上就是找出从 R^N 到 R^M 的非线性映射关系. 因此, 可以说径向基函数网络特别适用于非线性时间序列如太阳黑子数的预测^[23].

3 基于 R_{SSNy} 预测值采用 MLP 方法预测月降水量

以 R_{SSNy} 指数的 $t+1$ 月预报值为核心输入变量, 采用多层感知器 (MLP) 方法构建月降水量预报模型, 开展 $t+1$ 月降水量的预测研究. 数据选用湖南省邵阳市 1960 年 1 月至 2023 年 12 月的月降水量时序序列, 为保障模型构建的科学性与预报结果的可靠性, 将该完整数据序列按比例划分为训练集、测试集与验证集, 划分比例分别为 60%, 20% 与 20%, 用于模型的

参数训练、泛化能力检验及预报精度验证.

3.1 SSN_y 指数与月降水量的关系模型

将 f_B 模型表达成一个优化问题, 即

$$O_{\min,L,t} = |R_{M,t} - R_{L,t}|. \quad (3)$$

其中, $O_{\min,L,t}$ 为 t 时刻 MLP 模型预测月降水量与线性关系模型预测月降水量之差的最小化目标, $R_{M,t}$ 为 t 时刻 MLP 模型预测的月降水量, $R_{L,t}$ 为 t 时刻线性关系模型预测的月降水量. 等式约束条件为:

$$R_{L,t} = R_{SSN_{f,t}} - D_{f,t}, \quad (4)$$

$$R_{M,t} = f_B(R_{SSN_{f,t}}, \dots, R_{SSN_{o,t-1}}, \dots, D_{o,t}, \dots). \quad (5)$$

其中, $D_{f,t}$ 为 t 时刻月降水量与相应的太阳黑子 SSN_y 指数预测值之差, $D_{o,t}$ 为 t 时刻月降水量与相应的太阳黑子 R_{SSN_y} 指数实测值之差, f_B 为基于训练数据的 MLP 模型, $R_{SSN_{f,t}}$ 为 t 时刻 R_{SSN_y} 指数预测值, $R_{SSN_{o,t}}$ 为 t 时刻 R_{SSN_y} 指数实测值.

3.2 降水量丰枯指数

基于已构建的 R_{SSN_y} 指数与月降水量关联 f_B 模型, 通过数值求解获得一系列降水量极值序列, 该序列包含模型预测过程中的局部最优解 (局部极大值、局部极小值) 与全局最优解 (全局极大值、全局极小值). 为清晰阐释降水量丰枯指数 (RAI) 的定义逻辑, 以 1960 年 1 月的 SSN_y 指数预测值及率定后 f_B 模型的极值求解结果为典型案例进行说明. 对上述求解得到的极值序列按序编号, 具体编号规则与结果如图 2 所示.

由图 2 可知, 编号为 5 的极值为该模型预测的全局最优解 (全局极大值), 对应降水量为 217.99 mm.

图中黑线为粒子群算法求解的月降水量预报值, 方框值为按照月降水量预报值的极大值、极小值从小到大的排列顺序进行编号. 但从水文气象客观规律分析, 1 月份为湖南省邵阳市的传统少雨季节, 该区域当月降水量历史实测值普遍处于低水平区间, 模型预测得到的 217.99 mm 全局极大值与实际气候背景存在显著偏差, 难以直接用于降水量丰枯状态评估.

基于上述气候规律约束与实际应用需求, 将 f_B 模型求解得到的极值序列编号定义为降水量丰枯指数 (RAI). 该定义方式通过极值序列的相对排序特征量化降水量丰枯等级, 既解决了单一极值与区域气候背景不符的问题, 又能反映太阳活动驱动下降水量的相对丰枯演化规律, 具备明确的气候学意义与实用价值.

3.3 应用 MLP 方法对 RAI 真值序列建模

基于 1960 年 1 月至 2023 年 12 月的月降水量丰枯指数 (RAI) 真值序列, 可将月降水量预测问题转化为月 RAI 值的预测问题. 该转化过程既规避了单一降水量极值与区域气候背景不符的缺陷, 又能通过 RAI 值的时序演化特征捕捉太阳活动驱动下降水量丰枯状态的变化规律. 据此, 这里采用多层感知器 (MLP) 方法 $f_{B,RAI}$, 针对月 RAI 值时序序列开展建模分析, 通过构建 RAI 值预报模型间接实现月降水量的精准预测.

3.4 参照对比模型——MLP 常规建模方法

采用线性回归结合方差分解的方法, 定量核算太阳黑子 11 年周期活动对邵阳市降水变化的驱动贡献度. 结果表明, 太阳黑子 11 年周期活动对邵阳市降水变化的方差解释率为 11% ($p < 0.01$), 表明太阳活动仅能解释该区域降水总变异的 11%, 其余降水变化主要




图 2 极值系列实例 (以 1960 年 1 月的预测 R_{SSN_y} 指数和率定的 f_B 模型计算)

Fig. 2 Example of extreme value series (calculated based on the R_{SSN_y} and calibrated f_B model for January 1960)

受季风环流、局地地形、ENSO 等大气环流与下垫面因素共同主导.

为突出本文所提研究方法的创新性, 选取 MLP (Multilayer Perceptron) 模型作为对照基准模型, 并统一采用常规因子输入方案, 构建最优化问题如下:

$$O_{\min,O,t} = |R_{M,t} - R_{O,t}|. \quad (6)$$

其中, $O_{\min,O,t}$ 为 t 时刻 MLP 预测的月降水量与实测月降水量之差的最小化目标, $R_{M,t}$ 为 t 时刻 MLP 模型预测的月降水量, $R_{O,t}$ 为 t 时刻实测的月降水量. 等式约束条件为

$$R_{M,t} = f_M(R_{SSN_{f,t}}, \dots, R_{SSN_{o,t-1}}, \dots, R_{o,t}, \dots). \quad (7)$$

其中, f_M 为基于常规输入因子训练数据的 MLP 参照对比模型, $R_{SSN_{f,t}}$ 为 t 时刻 R_{SSN_Y} 指数预测值, $R_{SSN_{o,t}}$ 为 t 时刻 R_{SSN_Y} 指数实测值.

4 结果与分析

4.1 太阳黑子新指数

提出一种新的太阳活动量化指标——太阳黑子年滑月均值 R_{SSN_Y} 指数. 图 3 与图 4 分别给出了




图 3 1950 年 1 月至 2026 年 5 月 R_{SSN_Y} 指数未来第一个月的预测、实测及误差

Fig. 3 One-month lead prediction, observation, and error of R_{SSN_Y} index from January 1950 to May 2026




图 4 1950 年 1 月至 2026 年 5 月 R_{SSN_Y} 指数未来第二个月的预测、实测及误差

Fig. 4 Two-month lead prediction, observation, and error of R_{SSN_Y} index from January 1950 to May 2026

1950 年 1 月至 2026 年 5 月期间的 R_{SSNy} 指数未来第一个月 ($t+1$ 月) 和未来第二个月 ($t+2$ 月) 预测值、实测值的时序对比结果, 以及对应的绝对误差与相对误差分布特征。

针对未来第一个月 ($t+1$ 月) 的 R_{SSNy} 指数预测值 $D(n+1)$, 基于 917 个有效预测样本的统计分析结果表明: 所有预测样本的绝对误差均控制在 ± 12 以内, 其中 834 个样本的绝对误差 $\leq \pm 6.0$, 占总预测样本数的 95.09%(834/917); 所有预测样本的相对误差均处于 $\pm 58\%$ 以内, 进一步细分可知, 4 个样本的相对误差分布于 30%~58% 区间, 占总预测样本数的 0.44%(4/917), 其余 855 个样本的相对误差 $\leq \pm 10\%$, 占总预测样本数的 93.24%(855/917), 展现出优异的短期预测精度。

针对未来第二个月 ($t+2$ 月) 的 R_{SSNy} 指数预测值 $D(n+2)$, 基于 917 个有效预测样本的统计结果显示, 所有预测样本的绝对误差均控制在 ± 26 以内, 其中 899 个样本的绝对误差 $\leq \pm 15.0$, 占总预测样本数的 98.04%(899/917); 所有预测样本的相对误差均处于 $\pm 86\%$ 以内, 进一步细分可知, 6 个样本的相对误差分布于 50%~86% 区间, 占总预测样本数的 0.65%(6/917), 其余 911 个样本的相对误差均 $\leq \pm 50\%$, 占比 99.35%(911/917); 其中 855 个样本的相对误差 $\leq \pm 20\%$, 占总预测样本数的 93.24%(855/917)。

误差特征与太阳活动强度的关联分析表明, 在太阳活动高年, R_{SSNy} 指数数值偏高, 尽管预测绝对误差相对较大, 但相对误差较小; 而在太阳活动低年, R_{SSNy} 指数数值偏低, 虽预测相对误差有所增大, 但绝对误差处于较小水平。综合来看, 该方法对未来 2 个月的 R_{SSNy} 指数预测精度可满足业务应用需求, 具备良好的实用性。

对比传统 SSN 指数作为输入的方案, 采用 R_{SSNy} 指数构建的太阳活动预测模型, 在预报精度相当的前提下, 可将有效预报时效提前 5~6 个月, 时效性优势十分显著。例如以 2025 年 3 月 1 日为预报基准点, R_{SSNy} 指数的最新实测数据为 2025 年 2 月, 而 R_{SSN} 指数的最新实测数据仅能更新至 2024 年 8 月。同样开展未来 2 个月的预报, 基于 SSN 指数的预报模型仅能输出 2024 年 9 月和 10 月的预测结果, 对应预报基准点前第 6 个月和第 5 个月的数值, 无法实现前瞻性预报, 不能满足预报业务需求; 而基于 $SSNy$ 指数

的预报模型可直接输出 2025 年 3 月和 4 月的预测结果, 覆盖预报基准点未来 1~2 个月的时间范围, 精准满足业务对未来时段的预测需求。由此表明, 本文构建的 R_{SSNy} 太阳黑子年滑月均值指数, 有效解决了传统 13 个月平滑 R_{SSN} 指数存在 6 个月数据滞后的问题, 显著延长预报窗口, 为以太阳活动为驱动的相关参量预测提供了时效性支撑。

从预测机理逻辑层面分析, R_{SSNy} 指数物理合理性显著优于传统 R_{SSN} 指数。传统 R_{SSN} 指数以当月前后各 6 个月数据按特定权重加权计算, 不可避免引入当月之后未来 6 个月的实测数据, 用于预测建模时会形成“用未来数据反演过去”的逻辑悖论, 存在严重机理缺陷与业务局限性。而 $SSNy$ 指数仅通过该月份及此前 11 个月共计 12 个月的太阳黑子相对数月均值算术平均计算获得。将其作为输入因子应用于相关参量预测时, 建模输入均为已发生时序信息, 全程不引入任何未来数据, 严格遵循以历史信息推演未来状态的客观预测逻辑, 从根源上规避时序逻辑矛盾, 大幅提升太阳活动预测模型的科学性与严谨性。

4.2 R_{SSNy} 指数与月降水量的 MLP 模型

R_{SSNy} 指数与月降水量的多层感知器 (MLP) 模型输入变量包含两类: 一类为滞后 12 期的月太阳黑子数序列, 即 $SSN_t, SSN_{t-1}, SSN_{t-2}, \dots, SSN_{t-12}$ (其中 t 表示当前月份, $t-n$ 表示当前月份前第 n 个月); 另一类为滞后 12 期的差值序列 $D_t, D_{t-1}, \dots, D_{t-12}$ (其中 D_t 定义为第 t 月实测降水量 R_t 与同期及滞后 12 期月太阳黑子数序列 $[SSN_t, SSN_{t-1}, SSN_{t-2}, \dots, SSN_{t-12}]$ 的差值)。

模型训练与验证结果显示: 训练集的决定系数 (R^2) 为 0.99, 平均绝对误差 (MAE) 为 0.26, 均方根误差 (RMSE) 为 0.34; 测试集的决定系数 (R^2) 为 0.99, 平均绝对误差 (MAE) 为 0.27, 均方根误差 (RMSE) 为 0.38。两类数据集的评价指标均表现优异, 表明模型具备良好的拟合精度与泛化能力。

图 5 为模型在训练集与测试集上降水量预测的相对误差分布及散点拟合结果。整体来看, 模型训练阶段预测相对误差整体偏低, 96.5% 的样本相对误差 $< 8\%$; 测试阶段表现同样优异, 96.1% 的样本相对误差控制在 8% 以内。散点拟合结果也表明, 模拟值与实测值具有极强的相关性。

此处 R^2 数值偏高的原因, 很可能是此处 R_{SSNy}




图5 f_B 模型降水量预测。(a)训练集的相对误差,(b)测试集的相对误差,(c)模拟值与实测值的散点图

Fig. 5 f_B model-predicted precipitation.

(a) relative error (training set), (b) relative error (test set), (c) scatter plot of simulated versus observed values

指数值与月降水量本身数值变化趋势高度相近,同时 R_{SSNy} 指数的月度预测精度偏高,导致月模拟值与月实测值偏差极小。此处所呈现的看似过拟合现象仅体现在训练与测试阶段,模型实际预测效果并不理想,因此后续引入RAI指数开展预测研究。

PSO(Particle Swarm Optimization)参数需平衡探索能力与开发效率,既要避免早熟收敛导致解的最优性不足,也要兼顾计算效率以适配气候建模的工程需求。在相同收敛条件下(最大迭代200次),测试不同认知系数(c_1)与社会系数(c_2)组合对目标函数(Nash-Sutcliffe效率系数, NSE)的影响。参数结果见表1。

4.3 RAI指数的物理意义

以月降水量真值为基准,通过寻优方法确定

1960—2023年期间与月降水量真值最匹配的降水量丰枯指数(RAI)整数值系列。基于《水文情报预报规范》(GB/T 22482—2008)^[24]标准对RAI整数值对应的月降水量预报结果进行精度检验,结果显示:满足许可误差要求的合格率介于71.9%~95.3%之间,平均合格率达85.3%,表明基于RAI整数值的月降水量预报精度可满足规范要求。

图6及表2给出了1960—2023年期间各月份不同RAI整数值的出现频次特征,通过统计分析可得出以下结论:RAI=1的频次在1—2月、7—12月均为最高;3月频次最高的RAI值为2;4—6月频次最高的RAI值为3,该分布特征与研究区域降水的季节分配规律高度契合;高值RAI(RAI=6, 7)仅出现在5—6月,对应区域主汛期降水集中时段。

图7中各月份RAI值出现频次与RAI数值呈显著对数相关关系,决定系数(R^2)达0.976,表明RAI值的时序分布具有明确统计规律。图8重点呈现RAI值与降水量的线性相关特征,图8(a)用于表达RAI年值(定义为每年12个月RAI月值的总和)与年降水量的年际线性相关性,图8(b)用于表达RAI月均值与月降水量均值的年内线性相关性,二者均值均表现出良好的线性相关关系,RAI值与降水量在年际和年内尺度上均具有极强的线性一致性,进一步验证了RAI指数的科学性与实用性。尤为突出的是,RAI月均值与月降水量均值的决定系数(R^2)高达0.985,充分说明RAI值能够精准、有效地量化降水量的时空演化特征,可作为降水量丰枯状态评估的可靠指标。

上述系列分析结果表明,RAI指数的定义科学合理,能够准确反映研究区域降水量月分配的客观规律,为月降水量的精准预报提供了可靠的量化载体。

4.4 RAI真值系列建模

经多组方案试算验证,确定两种最优输入方案可使RAI预报模型获得理想性能,具体如下。

输入方案1. 选取滞后序列id1=[1:12, 27, 30, 35, 64, 67, 68, 123, 346],输入变量包括当前时刻预报太阳黑子数 $R_{SSNf,t}$ 、滞后时刻的实测降水量 $R_{o,t}(t-i)$, $i \in \text{id1}$ 、滞后时刻的实测太阳黑子数 $R_{SSNo,t}(t-i)$, $i \in \text{id1}$ 及滞后时刻的预报太阳黑子数 $R_{SSNf,t}(t-i)$, $i \in \text{id1}$ 。

输入方案2. 选取滞后序列id2=[1:12, 27, 30,

表 1 PSO 参数设置依据
Table 1 Basis for setting PSO parameters

参数	推荐值	设定依据	邵阳市案例适配调整
粒子数量	50~100	文献实证: Kennedy 等研究 ^[29] 表明, 粒子数量大于 30 时可有效避免早熟收敛, 保障解空间的覆盖度 计算效率: 邵阳市降水数据采用月度尺度, 数据维度较低, 无需过多粒子即可覆盖潜在解空间, 减少计算冗余	设定为 60, 既满足解的精度要求, 又控制计算成本, 单次迭代耗时控制在合理范围
惯性权重 ω	0.4~0.9 线性递减	理论基础: Shi 等提出 ^[30] , 高惯性权重可增强粒子的全局探索能力, 帮助跳出局部最优; 低惯性权重则可加速粒子向局部最优解收敛, 提升调优精度 动态策略: 初始阶段采用高 ω 扩大搜索范围, 避免错过全局最优解; 迭代末期采用低 ω 进行精细调优, 提升解的稳定性	迭代公式: $\omega_t = 0.9 - 0.5 \times (t/T_{\max})$, 其中 t 为当前迭代次数, $T_{\max}$ 为最大迭代次数, 实现惯性权重的动态自适应调整
认知系数 c_1	1.5~2.0	个体学习权重: 认知系数控制粒子对自身历史最优位置的学习能力, >2.0 时, 易导致粒子轨迹振荡, 降低收敛效率; <1.0 时, 则会使粒子学习能力不足, 收敛速度过慢 实验验证: 通过参数扫描实验发现, 当 $c_1=1.7$ 时, 目标函数 NSE 较其他取值提升 12%, 适配性最优	固定为 1.7, 通过网格搜索法确定, 确保粒子个体学习能力与收敛稳定性的平衡
社会系数 c_2	1.5~2.0	群体协作权重: 社会系数控制粒子对群体最优位置的学习能力需与认知系数协同作用, 共同控制粒子轨迹的合理性 敏感性分析: 通过正交实验验证, 当 $c_2=1.8$ 时, 粒子群多样性最优, 可有效避免早熟收敛, 同时保障收敛速度	固定为 1.8, 经正交实验验证, 与 $c_1=1.7$ 组合时, 目标函数值达到最优
速度限幅	$\pm 20\%$ 解空间范围	防止粒子速度过快导致轨迹振荡, 避免粒子跳出合理空间; 结合邵阳市降水序列特性, 降水值域为 0~400 mm, 20% 的限幅可兼顾探索性与稳定性	动态约束: $v_{\max} = 0.2 \times (x_{\max} - x_{\min})$, 其中 $x_{\max}$, $x_{\min}$ 分别为降水序列的最大值与最小值, 即 $v_{\max} = 80 \text{ mm} \cdot \text{month}^{-1}$, 适配邵阳降水数据范围




图 6 1960—2023 年期间最优 RAI 整数值在各月的出现次数

Fig. 6 Number of occurrences of the optimal RAI value in each month during 1960—2023

35, 64, 67, 68, 123], 输入变量与方案 1 一致, 仅滞后序列剔除 $\text{id}=346$ 项, 即输入变量为 $R_{\text{SSN}_{f,t}}$, $R_{o,t}(t-j)$, $j \in \text{id}1$, $R_{\text{SSN}_{o,t}}(t-j)$, $j \in \text{id}1$ 及 $R_{\text{SSN}_{f,t}}(t-j)$, $j \in \text{id}1$. 两种方案的模型输出均为当前时刻降水

量丰枯指数 RAI.

模型构建过程中, 将全时序数据集按 60%, 20%, 20% 的比例划分为训练集、验证集与测试集, 分别用于模型参数训练、结构优化与泛化能力检验. 采用固

表 2 1960—2023 年期间最优 RAI 整数值出现次数
Table 2 Occurrence of the RAI value in each month during 1960—2023

RAI	1月	2月	3月	4月	5月	6月	7月	8月	9月	10月	11月	12月	出现次数
1	41	35	19	9	7	3	22	25	40	32	38	52	323
2	16	20	23	15	8	15	17	14	10	13	13	7	171
3	5	8	14	21	26	20	15	11	11	12	9	5	157
4	2	1	6	14	14	10	5	12	1	3	4	0	72
5	0	0	2	5	6	14	5	2	2	4	0	0	40
6	0	0	0	0	2	1	0	0	0	0	0	0	3
7	0	0	0	0	1	1	0	0	0	0	0	0	2
合格率/(%)	81.3	76.6	93.8	92.2	90.6	87.5	95.3	90.6	82.8	82.8	78.1	71.9	85.3




图 7 1960—2023 年 RAI 整数值与每月出现次数的关系

Fig. 7 Relationship between the RAI and the occurrence quantity during 1960—2023

定网络结构开展模型训练, 具体结构为: 61 个输入神经元—10 个神经元的第 1 隐藏层—5 个神经元的第 2 隐藏层—1 个输出神经元 (61 输入-10 隐藏-5 隐藏-1 输出).

性能评价结果显示: 基于输入方案 1 的 RAI_id1 模型, 纳什效率系数 (NSE) 可达 0.52 以上, 显著优于均值预测模型 (NSE=0.2895); 其训练集、验证集、测试集及全数据集的相关系数 (R) 分别为 0.83, 0.51, 0.53 和 0.73. 基于输入方案 2 的 RAI_id2 模型, 训练集、验证集、测试集及全数据集的相关系数 (R) 分别为 0.77, 0.32, 0.51 和 0.67, 整体性能略逊于 RAI_id1 模型.

直接采用 RAI 均值, 基于《水文情报预报规范》(GB/T 22482—2008) 标准, 1960—2023 年每月的平均合格率在 36%~63%, 均值为 52%. 采用 RAI_id1

模型, 1960—2023 年每月的平均合格率在 47%~74%, 均值为 62%. 采用 RAI_id2 模型, 1960—2023 年每月的平均合格率在 48%~72%, 均值为 63%.

值得注意的是, 三种预报方法的最小合格率均出现在 5—6 月, 该时段恰好对应 RAI 最大值及月降水量最大值的集中出现期. 该现象表明, 5—6 月作为研究区域的降水峰值期, 其降水量不仅受太阳活动因素调控, 还可能受区域气候特征、大气环流季节转换等多重复杂气象与地理要素共同叠加影响, 5—6 月正值环流调整、对流活动多发叠加期, 气候系统不稳定性高, 降水突发性、局地性特征显著, 是造成该时段预报精度相对偏低的主要原因. 图 9 和表 3 为 RAI_id1 模型和 RAI_id2 模型预测值在各月的平均合格率.

4.5 参照对比模型——MLP 常规建模方法

太阳黑子 11 年周期活动仅能解释降水量变化的

11%, 其余变异特征主要受季风环流、地形起伏、EN-SO 事件等综合因素主导. 采用常规建模方法进行参数率定、模型训练与验证时, 拟合效果普遍较差, 决定系数 R^2 均低于 0.3. 相比之下, 本文所构建的模型方法体现出良好的创新性与普适性.

5 结论与讨论

围绕太阳活动与月降水量关联预报展开系列研究, 核心成果之一是提出了一种新的太阳活动水平量




图 8 (a) RAI 年值与年降水量的关系, (b) RAI 月均值与月降水量的关系

Fig. 8 (a) Relationship between RAI annual value and annual precipitation, (b) relationship between RAI monthly mean and monthly precipitation

化指标——太阳黑子相对数年滑动月均值 R_{SSNy} 指数. 该指数有效解决了传统 13 个月太阳黑子相对数平滑月均值 R_{SSN} 指数 6 个月的数据获取延迟问题, 通过仅采用当月及此前 11 个月的历史数据计算, 解决了传统指数引入未来信息预测过去的逻辑悖论, 更契合预测逻辑. 精度验证表明, R_{SSNy} 指数对未来 1~2 个月的预测效果优异, $t+1$ 月预测中 93% 样本的相对误差 $\leq \pm 10\%$, $t+2$ 月 93% 以上样本的相对误差 $\leq \pm 20\%$, 且在保证相同预测精度的前提下, 预报时效较传统 R_{SSN} 指数提前 5~6 个月, 可有效满足业务预报对时效性的需求.

在此基础上, 还可对指数进行延伸, 在年滑月均值的基础上, 对每个月的黑子相对数月均值取不同的权重, 寻找与模型预报参量的相关性, 从而提高模型的预报精度, 计算公式为

$$R_{SSNy_{ci}} = \sum (c_{11}R_{SN_{i-11}} + c_{10}R_{SN_{i-10}} + \dots + c_1R_{SN_{i-1}} + c_0R_{SN_i}). \quad (8)$$

其中, c_0 至 c_{11} 为所计算月份至其之前 11 个月的权重系数, $R_{SSNy_{ci}}$ 为不同权重系数下的年滑月均值, 其余参数与式 (2) 意义相同. 通常情况下, 所计算当月的权重系数最大, 越远离该月份其权重系数越小, 可以先给定一组和为 1 的权重系数的初值, 例如等差数列 $c_0 \sim c_{11}$, $[33/264, 31/264, 29/264, 27/264, 25/264, 23/264, 21/264, 19/264, 17/264, 15/264, 13/264, 11/264]$, 权重系数可以在相关参量预测模型的分析中进行调整, 寻求最佳系数组合, 以达到最优的相关性^[31].

基于 R_{SSNy} 指数构建了多套月降水量及降水量丰枯指数 (RAI) 预报模型, 明确了太阳活动与月降水量的关联规律及有效预报路径. 以 R_{SSNy} 指数为核心




图 9 RAI_id1 模型和 RAI_id2 模型预测值各月平均合格率

Fig. 9 Average qualification rate in each month of RAI_id1 model and RAI_id2 model

输入构建的 MLP 月降水量关联模型, 拟合与泛化能力突出, 训练集与测试集决定系数 (R^2) 均达 0.99; 通过整合模型预测极值序列定义的 RAI 指数, 可有效量化降水量丰枯状态, 其分布特征与研究区域降水季节分配规律高度契合, 且 RAI 月均值与月降水量均值的线性相关系数 (R^2) 达 0.985, 能准确反映降水量月分配客观规律. 基于最优输入方案的 RAI 预报模型 (RAI_id1) 纳什效率系数 (NSE) 达 0.52 以上, 对应月降水量预报平均合格率提升至 62%, 精度满足《水文情报预报规范》(GB/T 22482—2008) 要求.

研究建立的 R_{SSNy} 指数构建—太阳活动—降水关联建模—RAI 指数优化预报技术框架, 为中长期月降水量预报提供了新的技术路径与理论支撑, 突破了传统预报仅依赖局地气象因子的局限. 但研究也发现, 5~6 月降水峰值期的预报精度仍相对偏低, 表明该时段降水受气候特征、大气环流等多因素综合影响, 太阳活动单一驱动因子的解释力有限. 未来可进一步引入多源气候、气象等数据, 构建多因子融合预报模型, 同时拓展研究区域至不同气候区, 验证 R_{SSNy} 指数及预报模型的普适性, 进一步提升中长期降水预报的精度与可靠性.

医学伦理 研究不涉及人体或动物实验.

利益冲突 所有作者均声明不存在利益冲突.

参考文献

- [1] ZHANG H B, SINGH V P, WANG B, *et al.* CEREF: a hybrid data-driven model for forecasting annual streamflow from a socio-hydrological system[J]. *Journal of Hydrology*, 2016, **540**: 246-256
- [2] SUN F F, SHENG D, MA M M, *et al.* Evaluation on implementation of water law in China[J]. *Water Resources Management*, 2019, **33**(7): 2599-2613
- [3] LIN Zuoding, ZHU Jinfeng, WANG Kun. Hydrological practice and reflection on promoting the high-quality development of the Yangtze River economic belt[J]. *Water Resources Development Research*, 2024, **24**(2): 16-21 (林祚顶, 朱金峰, 王琨. 推动长江经济带高质量发展的水文实践与思考 [J]. *水利发展研究*, 2024, **24**(2): 16-21)
- [4] LI H Y, XUE L J, WANG X J. Relationship between solar activity and flood/drought disasters of the Second Songhua river Basin[J]. *Journal of Water and Climate Change*, 2015, **6**(3): 578-585
- [5] FRIIS-CHRISTENSEN E, LASSEN K. Length of the solar cycle: an indicator of solar activity closely associated with climate[J]. *Science*, 1991, **254**(5032): 698-700
- [6] YONABA R, MOUNIROU L A, TAZEN F, *et al.* Future climate or land use? Attribution of changes in surface runoff in a typical Sahelian landscape[J]. *Comptes Rendus. Géoscience*, 2023, **355**(S1): 411-438
- [7] CHEN X, LI F W, FENG P. A new hybrid model for non-linear and non-stationary runoff prediction at annual and monthly time scales[J]. *Journal of Hydro-environment Research*, 2018, **20**: 77-92
- [8] TIAN J, NELSON D M, HU F S. Possible linkages of Late-Holocene drought in the North American midcontinent to Pacific Decadal Oscillation and solar activity[J]. *Geophysical Research Letters*, 2006, **33**(23): L23702
- [9] LI C H, YANG Z F, HUANG G H, *et al.* Identification of relationship between sunspots and natural runoff in the Yellow River based on discrete wavelet analysis[J]. *Expert Systems with Applications*, 2009, **36**(2): 3309-3318
- [10] RIND D. The sun's role in climate variations[J]. *Science*, 2002, **296**(5568): 673-677
- [11] SHINDELL D T, SCHMIDT G A, MANN M E, *et al.* Solar forcing of regional climate change during the maunder minimum[J]. *Science*, 2001, **294**(5549): 2149-2152
- [12] KELLY P M, WIGLEY T M L. Solar cycle length, greenhouse forcing and global climate[J]. *Nature*, 1992, **360**(6402): 328-330
- [13] LABITZKE K, VAN LOON H. Some recent studies of probable connections between solar and atmospheric variability[J]. *Annales Geophysicae*, 1993, **11**(11/12): 1084-1094
- [14] ZHAO J, HAN Y B, LI Z A. The effect of solar activity on the annual precipitation in the Beijing area[J]. *Chinese Journal of Astronomy and Astrophysics*, 2004, **4**(2): 189-197
- [15] JONES P D, JONSSON T, WHEELER D. Extension to the North Atlantic oscillation using Early instrumental pressure observations from Gibraltar and south-west Iceland[J]. *International Journal of Climatology*, 1997, **17**(13): 1433-1450
- [16] KANE R P. Prediction of droughts in North-East Brazil: role of ENSO and use of periodicities[J]. *International Journal of Climatology*, 1997, **17**(6): 655-665
- [17] PEKÁROVÁ P, MIKLÁNEK P, PEKÁR J. Spatial and temporal runoff oscillation analysis of the main rivers of the world during the 19th-20th centuries[J]. *Journal of Hydrology*, 2003, **274**(1/2/3/4): 62-79
- [18] WRZESIŃSKI D, SOBKOWIAK L, MARES I, *et al.* Variability of river runoff in Poland and its connection to solar variability[J]. *Atmosphere*, 2023, **14**(7): 1184
- [19] LIN Zuoding. Seriously implement the water management concept of "water conservation priority, spatial balance, systematic governance, and dual pronged efforts" to accelerate the high-quality development of hydrology[J]. *Water Resources Development Research*, 2021, **21**(7): 5 (林祚顶. 认真贯彻落实“节水优先、空间均衡、系统治理、两手发力”的治水思路加快推进水文高质量发展 [J]. *水利发展研究*, 2021,

- 21(7): 38-42)
- [20] LI H Y, WANG Y X, LI X B. Mechanism and forecasting methods for severe droughts and floods in Songhua River Basin in China[J]. *Chinese Geographical Science*, 2011, 21(5): 531-542
- [21] WANG Shaowu, HUANG Jianbin, WEN Xinyu. Implications of paleoclimate[J]. *Meteorological Monthly*, 2012, 38(3): 257-265 (王绍武, 黄建斌, 闻新宇. 古气候的启示 [J]. 气象, 2012, 38(3): 257-265)
- [22] DING Yihui. Effect of solar activity on earth's climate and weather[J]. *Meteorological Monthly*, 2019, 45(3): 297-304 (丁一汇. 太阳活动对地球气候和天气的影响 [J]. 气象, 2019, 45(3): 297-304)
- [23] ZHAO Haijuan, WANG Jialong, ZONG Weiguo, et al. Prediction of the smoothed monthly mean sunspot numbers by means of radial basis function neural networks[J]. *Chinese Journal of Geophysics*, 2008, 51(1): 31-35 (赵海娟, 王家龙, 宗位国, 等. 用径向基函数神经网络方法预报太阳黑子数平滑月均值 [J]. 地球物理学报, 2008, 51(1): 31-35)
- [24] China National Standardization Committee. GB/T 22482-2008, Standard for hydrological information and hydrological forecasting[S]. Beijing: Standards Press of China, 2008 (中国国家标准委员会. GB/T 22482-2008, 水文情报预报规范 [S]. 北京: 中国标准出版社, 2008)
- [25] HU J L, MIAO C Y, SU J J, et al. An upgraded high-precision gridded precipitation dataset for the Chinese mainland considering spatial autocorrelation and covariates[J]. *Expert System Science Data*, 2025, 17(8): 3987-4004
- [26] ZHAO Haijuan, LIU Dandan. Method for predicting long-term solar activity level: CN, 202510842311.0[P]. 2025-06-23 (赵海娟, 刘丹丹. 一种预测长期太阳活动水平的方法: 中国, 202510842311.0[P]. 2025-06-23)
- [27] Xu Dong, Wu Zheng. Systems analysis and design based on MATLAB6-X-Neural Network. Xi'an: Xidian University Press 2002 (许东, 吴铮. 基于 MATLAB6. X 的系统分析与设计—神经网络 [M]. 2 版. 西安: 西安电子科技大学出版社, 2002)
- [28] Beijing FCIT Sc-i Tech Center. The application of neural network and MATLAB 7. Beijing: Publishing House of Electronics Industry, 2005 (飞思科技产品研发中心. 神经网络理论与 MATLAB 7 实现 [M]. 北京: 电子工业出版社, 2005)
- [29] KENNEDY J, EBERHART R. Particle swarm optimization[C]. *Proceedings of the IEEE International Conference on Neural Networks*. Perth: IEEE Press, 1995: 1942-1948
- [30] SHI Y H, EBERHART R C. Empirical study of particle swarm optimization[C]. *Proceedings of the IEEE Congress on Evolutionary Computation*. Washington DC: IEEE Press, 1999: 1945-1950
- [31] ZHAO Haijuan, LIU Dandan. Method for predicting long-term solar activity level based on F107 index annual lunar mean value: CN, 202510842310.6[P]. 2025-06-23 (赵海娟, 刘丹丹. 一种基于 F107 指数年滑月均值预测长期太阳活动水平的方法: 中国, 202510842310.6[P]. 2025-06-23)

作者简介



赵海娟 女, 1977 年 4 月出生于河北省滦南县, 现为国家卫星气象中心 (国家空间天气监测预警中心) 高级工程师, 主要研究方向为太阳活动预报及空间天气预报.

E-mail: zhaohj@cma.cn



孙飞飞 (通信作者) 男, 1985 年 5 月出生于江苏省灌南县, 现为中水北方勘测设计研究有限责任公司高级工程师, 主要研究方向为中长期降水预报及工程安全等.

E-mail: f556sun@163.com