

基于变分模态分解和支持向量回归的混沌降水量序列预测

郝政¹, 马少娟^{1,2*}, 陈泓霖¹

¹北方民族大学数学与信息科学学院 宁夏银川

²宁夏智能信息与大数据处理重点实验室 宁夏银川

【摘要】 准确的降水量预测对暴雨以及洪涝灾害的防治具有重要意义。由于传统降水量预测方法对信息挖掘能力不足, 在变分模态分解 (VMD) 基础上结合机器学习提出一种改进的变分模态分解和支持向量回归 (VMD-SVR) 预测方法。以郑州市为例, 首先分析了该城市 1979-2020 年逐月降水量序列的混沌特性; 其次对降水量序列的原始序列数据、相空间重构数据和变分模态分解数据进行预测, 结果显示变分模态分解后的数据预测性能较高; 最后对比三种机器学习算法预测变分模态分解数据结果的精度, 发现 VMD-SVR 模型预测精度最高。

【关键词】 变分模态分解; 支持向量回归; 混沌时间序列; 降水量预测

【基金项目】 国家自然科学基金项目 (11772002), 全国统计科学研究项目 (2020LY046)

【收稿日期】 2022 年 12 月 25 日 **【出刊日期】** 2023 年 1 月 29 日 **【DOI】** 10.12208/j.aam.20230001

Chaotic precipitation series prediction based on VMD and SVR

Zheng Hao¹, Shaojuan Ma^{1,2*}, Honglin Chen¹

¹School of Mathematics and Information Science, North Minzu University, Yinchuan

²Ningxia Key Laboratory of Intelligent Information and Big Data Processing, Yinchuan

【Abstract】 Accurate precipitation prediction has a great significance to the prevent and control of rainstorm and flood disasters. Due to the lack of information mining ability of traditional precipitation prediction methods, the improved Variational Mode Decomposition (VMD) and Support Vector Regression (VMD-SVR) prediction method was proposed. Taking Zhengzhou as an example, firstly the chaotic characteristics of monthly precipitation series in the city from 1979 to 2020 were analyzed. Secondly, the original series data, phase space reconstruction data and variational mode decomposition data of precipitation series are predicted. The results show that the data prediction performance after variational mode decomposition is higher. Finally, the prediction accuracy of the three machine learning algorithms was compared, the VMD-SVR model was found to have the highest prediction accuracy.

【Keywords】 Variational Mode Decomposition; Support Vector Regression; Chaotic Time Series; Prediction of precipitation

1 引言

在气候变化影响下, 全球极端气候事件越来越频繁, 预测和防范极端气象事件成为一个越来越受关注的课题。暴雨是一次短时的或连续的强降水过程, 会在地势低洼、地形闭塞等不能迅速宣泄的区域造成灾害; 甚至会引起山洪暴发、江河泛滥、堤坝决口, 给社会造成重大经济损失。暴雨灾害的主要评价指标是降水量, 降水量是非线性、非稳定性的时间序列, 若能较精准地预测区域的降水量, 对实现防灾减灾具有十分重要的指导意义^[1,2]。

影响降水量的因素众多, 降水的内部机理和形成机制比较复杂, 以机理为依据的长期预测难度比较大^[3]。

作者简介: 作者简介: 郝政 (1997-) 硕士, 研究方向为经济社会统计;

*通讯作者: 马少娟 (1979-) 女, 博士, 教授, 博导, 研究方向为非线性预测

因此, 国内外学者主要采取以时间序列统计学分析为主的方法对降水量的预测问题进行分析。迟道才等^[4]将 ARIMA 和蒙特卡洛方法应用于降水量的预测, 提高了预测精度。Byung 等^[5]选取 ARIMA 模型对蒙古地区降水量进行季节性预测。Priya 等^[6]采用 ARIMA 模型对印度西部季风前降雨数量的趋势进行分析。余霖等^[7]通过一种十字交叉选择算法, 提出了一种基于降水量序列平稳性和周期性多分支的降水量预测模型。郝慧慧等^[8]提出了一种改进灰色波形预测方法对降水量进行预测。吴林川等^[9]运用加权马尔科夫链模型对榆林地区年降水量范围进行预测, 并根据模糊集理论预测年降水量。由于降水量数据具有较强的周期性, 关联因素众多, 不确定性高等原因, 传统的统计方法不能很好的探索降水量时间序列的内部机理, 对降水量的预测有一定的偏差。

随着机器学习的提出和发展, 许多学者开始转向利用机器学习预测模型对降水量数据进行预测。贺佳佳等^[10]构建了一种多时间尺度的支持向量机降水量预测模型, 该模型对局部短时降水预测有较好的效果。贺玉琪等^[11]提出了支持向量回归和贝叶斯岭回归结合对降水量预测的方法。甄亿位等^[12]用随机森林模型研究中长期降水量预测, 发现随机森林模型效率高, 性能优, 适用于大样本的逐月降水量预测。卢维学等^[13]提出基于随机森林算法的偏最小二乘回归模型, 对降水量进行预测。吴群等^[14]提出了一种基于遗传算法的 RBF 神经网络模型用于降水量的预测。降水量时间序列具有较为复杂的非线性, 单一的机器学习模型可能会有一定的误差, 于是舒涛^[15]等将混沌理论应用于降水量时间序列进行预测。Chaitanya 等^[16]和 Manlio 等^[17]将混沌理论与神经网络相结合对降水量进行预测, 来提升预测精度。由于混沌时间序列对初始值较为敏感, 进行相空间重构时, 初始参数设定有细微的差异就会对预测结果产生很大的影响, 变分模态分解 (VMD) 能很好的解决这一问题。VMD 具有很好的去噪性能, 同时可以避免模态混叠现象, 能准确的区分出相似频率的序列。孙望良等^[18]提出了一种基于 VMD 和趋势波动分析的 LSTM 组合模型对日径流量进行预测, 有效提高了径流预报精度。徐冬梅等^[19]运用 VMD-TCN 模型来对宽坪地区的月降水量进行预测, 结论显示所提方法预测精度较高。

通过以上文献分析, 降水量时间序列具有复杂的非线性, 应用混沌时间序列对其分析时, 初始值的敏感性和时间序列的噪声会对预测结果产生较大的影响, 变分模态分解的方法更加适合降水量的预测, 尤其是变分模态分解结合机器学习算法进行降水量预测会有较高的精度。现有文献提出基于 VMD 与 TCN 等神经网络类型方法存在实现比较困难或在长时间的训练中常常出现过拟合等问题。基于此, 本文提出在支持向量回归基础上的 VMD-SVR 模型对郑州市的月降水量进行预测。

2 降水量时间序列的非线性特性分析

2.1 数据概述

降水量数据是来自美国国家海洋和大气管理局每日更新的 0.5 度纬度×0.5 度经度网格下载的 nc 数据文件, 用 matlab 对其进行读取并整理, 得到 1979-2020 年郑州市月平均降水量, 如图 1。根据收集到的数据可知, 2020 年郑州年降水量是 1107.22mm, 为历年降水量最高值, 1986 年郑州年降水量是 343.74mm, 为历年降水量最低值。1979-2020 年郑州市年降水量大于 800mm 的有 4 次, 年降水量小于 400mm 的有 3 次。根据月降水量可以看出, 历年单月降水量大于 200mm 的有 17 次, 其中历年 7 月降水量大于 200mm 的有 9 次。郑州的降水主要集中在 5-9 月, 7 月份降水最多, 见图 1。

2.2 混沌特性分析

由特征分析可知, 月降水量系统是非线性的时间序列, 具有一定程度的混沌特性, 因此可以应用混沌时间序列理论进行预测。首先根据 C-C 法确定相空间重构参数时间延迟 τ 和嵌入维数 d , 然后对月降水量数据进行相空间重构, 最后利用 wolf 法求得 Lyapunov 指数进行混沌特征识别。

(1) C-C 法相空间重构

C-C 法是使用关联积分估算出时间延迟和嵌入维数, 同时考虑 τ 和 d , 利用嵌入时间序列的关联积分分析得到时间序列的相关性, 得出统计量 $\bar{S}(\tau)$ 、 $S_{cor}(\tau)$ 和 $\Delta\bar{S}(\tau)$, 根据 $\bar{S}(\tau)$ 、 $S_{cor}(\tau)$ 、 $\Delta\bar{S}(\tau)$ 和 τ 的关系来获得最佳延迟时间 τ_d 和嵌入窗 τ_w , 最后求出嵌入维数 d 。

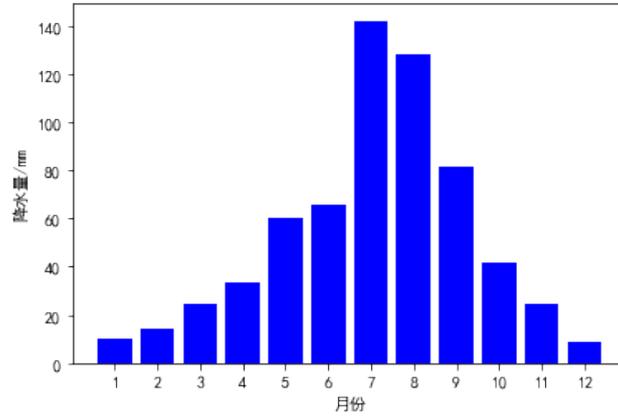


图 1 1979-2020 年郑州月平均降水量

混沌时间序列 $x = \{x_i | i = 1, 2, \dots, N\}$, 以时间延迟 τ 和嵌入维数 d 重构相空间 $X = \{X_i\}$, X_i 为相空间中的点, 则嵌入时间序列的关联积分为:

$$C(d, N, r, t) = \frac{2}{M(M-1)} \sum_{1 \leq i < j \leq M} \theta(r - d_{ij}), r > 0, \quad (1)$$

其中 $d_{ij} = \|X_i - X_j\|_{(\infty)}$, 表示 X_i 与 X_j 之间的欧式距离; $\theta(\cdot)$ 是 Heaviside 单位函数, 当 $x < 0$ 时, $\theta(x) = 0$; 当 $x \geq 0$ 时, $\theta(x) = 1$ 。关联积分是个累积分布函数, 表示相空间中两点间的距离小于 r 的概率。

首先, 将月降水量时间序列 $x = \{x_i | i = 1, 2, \dots, N\}$ 分解成 τ 个子序列:

$$\begin{cases} x^1 = \{x_i | i = 1, \tau + 1, \dots, N - \tau + 1\}, \\ x^2 = \{x_i | i = 2, \tau + 2, \dots, N - \tau + 2\}, \\ \dots\dots \\ x^\tau = \{x_i | i = \tau, 2\tau, \dots, N\}. \end{cases}$$

其中 N 是 τ 的整数倍。计算 τ 个子序列:

$$S(d, N, r, \tau) = \frac{1}{\tau} \sum_{s=1}^{\tau} \left[C_s \left(d, \frac{N}{\tau}, r, \tau \right) - C_s^d \left(d, \frac{N}{\tau}, r, \tau \right) \right],$$

当 $N \rightarrow \infty$ 时, 有:

$$S(d, r, \tau) = \frac{1}{\tau} \sum_{s=1}^{\tau} \left[C_s(d, r, \tau) - C_s^d(d, r, \tau) \right],$$

如果时间序列 $x = \{x_i | i = 1, 2, \dots, N\}$ 独立同分布, 那么当 d, τ 固定且 $N \rightarrow \infty$ 时, 对于所有的 r 均有 $S(d, r, \tau)$ 恒等于零。但降水量时间序列有限且元素之间存在一定的关性, 实际得到的 $S(d, r, \tau)$ 不为零, 有一定的偏差, 其最大偏差为:

$$\begin{aligned} \Delta S(d, \tau) &= \max \{S(d, r_j, \tau)\} - \min \{S(d, r_j, \tau)\}, \\ d &= 2, 3, 4, 5, j = 1, 2, 3, 4. \end{aligned}$$

其次, 选取适当的数据长度 N , 计算 $\bar{S}(\tau)$ 、 $\Delta \bar{S}(\tau)$ 、 $S_{cor}(\tau)$,

$$\bar{S}(\tau) = \frac{1}{16} \sum_{d=2}^5 \sum_{j=1}^4 S(d, r_j, \tau),$$

$$\Delta \bar{S}(\tau) = \frac{1}{4} \sum_{d=2}^5 \Delta S(d, \tau),$$

$$S_{cor}(\tau) = \Delta \bar{S}(\tau) + |\bar{S}(\tau)|,$$

其中, $r_j = j \frac{\sigma}{2}, j=1,2,3,4$, σ 为时间序列的标准差。

最后求出嵌入维数 d

$$d = \frac{\tau_w}{\tau_d} + 1, \quad (2)$$

其中, τ_w 为 $S_{cor}(\tau)$ 最小值对应的时间延迟, τ_d 为 $\Delta \bar{S}(\tau)$ 第一个极小值所对应的时间延迟。

针对 1979-2020 年月降水量时间序列数据做 $S_{cor}(\tau)$ 和 $\Delta \bar{S}(\tau)$ 统计量图, 从图 2 和图 3 可以看出 $\Delta \bar{S}(\tau)$ 第一个极小值对应的时延为 3, $S_{cor}(\tau)$ 最小值对应的时延为 24, 则 $\tau_d = 3$ 、 $\tau_w = 24$, 根据式(2)计算嵌入维数 $d = 9$, 得出郑州市 1979-2020 年月降水量时间序列相空间重构的 2 个重构参数时间延迟为 3, 嵌入维数为 9。

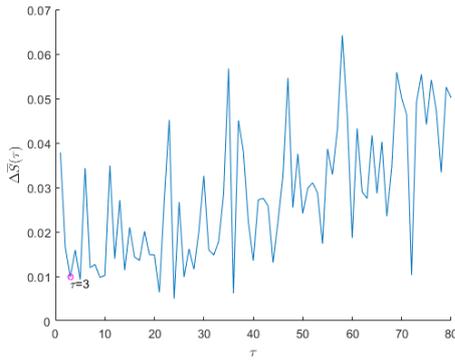


图 2 $\Delta \bar{S}(\tau)$ 值

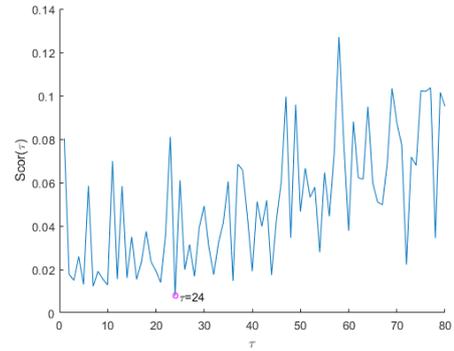


图 3 $S_{cor}(\tau)$ 值

(2) 混沌识别

本文根据 C-C 算法求出郑州市 1979-2020 年月降水量时间序列的时间延迟 τ 和嵌入维数 d , 运用 wolf 法^[20]求 Lyapunov 指数得到 $\lambda = 0.0605$, 说明郑州 1979-2020 年月降水量时间序列存在混沌特性, 该序列为混沌时间序列, 可以做短期预测。

3 降水量预测模型构建

3.1 变分模态分解

变分模态分解 (Variational Mode Decomposition, VMD) 是以 Hilbert 变换、Wiener 滤波和频率混合为基础的自适应、完全非递归的信号处理方法, VMD 的目的是将初始信号分解为具有固定带宽和中心频率的本征模态函数 (Intrinsic Mode Function, IMF), 它具有很好的去噪效果, 避免了频谱混叠现象, 能够准确区分相似频率的序列。该方法的优点是可以确定模态分解的数量。假设原始信号分解为 K 个分量, 对应的约束变分问题如下:

$$\min_{\{u_k, \omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\}$$

$$s.t. \sum_{k=1}^K u_k(t) = f(t),$$

其中 $u_k(t)$ 为第 k 个模态, ω_k 为每个模态的第 k 个中心频率, $\delta(t)$ 为狄拉克分布。

为求解上述问题, 引入二次惩罚因子 α 和拉格朗日乘子 $\lambda(t)$, 通过 $\lambda(t)$ 保持约束的严格性, 将约束问题转化为非约束问题进行求解。

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \right\rangle. \quad (3)$$

α 能有效降低高斯白噪声的影响, 其值越小分解得到 IMF 的带宽越大, 反之越小。为了不断求解 u_k 和 ω_k , 将式(3)问题转化为求解极小值问题:

$$u_k^{n+1} = \arg \min \left\{ \alpha \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{i=1}^K u_i(t) + \frac{\lambda(t)}{2} \right\|_2^2 \right\}. \quad (4)$$

式(4)中的问题可用交替方向乘子法求解, 模态 u_k 和中心频率 ω_k 的最优解表示如下:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + (\hat{\lambda}(\omega)/2)}{1 + 2\alpha(\omega - \omega_k)^2},$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega},$$

其中, $\hat{f}(\omega)$, $\hat{u}_i(\omega)$, $\hat{\lambda}(\omega)$, $\hat{u}_k^{n+1}(\omega)$ 分别为 $f(\omega)$, $u_i(\omega)$, $\lambda(\omega)$, $u_k^{n+1}(\omega)$ 的傅里叶变换。

u_k 和 ω_k 更新后, 拉格朗日乘子也依据式(5)进行更新:

$$\hat{\lambda}^{\hat{n}+1}(\omega) = \lambda^n(\omega) + \tau \left(\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right). \quad (5)$$

重复上述过程直至满足下列条件:

$$\sum_k \frac{\left\| \hat{u}_k^{n+1} - u_k^n \right\|_2^2}{\left\| \hat{u}_k^n \right\|_2} < \varepsilon.$$

3.2 支持向量回归

支持向量回归 (Support Vector Regression, SVR) [21] 是一种基于有限样本统计学理论的机器学习方法。SVR 依据结构风险最小化原则, 在高维特征空间中寻找一个最优超平面, 可以准确无误的将训练样本 $(x_i, y_i), (i=1, 2, \dots, n)$ 分开, 其中 x_i 为样本输入值, y_i 为样本输出值。设超平面的表达式为:

$$w\phi(x_i) + b = 0,$$

其中, w 为权重矢量, b 为偏置项, $\phi(\cdot)$ 为目标函数。

将寻找最优超平面问题归结为求解如下约束优化问题,

$$\begin{aligned} \min \phi(w, e) &= \frac{1}{2} \|w\|^2 + \frac{\gamma}{2} \sum_{k=1}^n e_k^2, \\ s.t. (w\phi(x_i) + b) - 1 + e_k &\geq 0, e_k \geq 0, \end{aligned}$$

其中, γ 为惩罚因子, e_k 为松弛因子。

对 γ 寻优, 进行一系列求解得到最优回归函数:

$$y(x) = \sum_{k=1}^N \alpha_k K(x, x_k) + b,$$

其中, α_k 为最优拉格朗日乘子, x 表示不同于 x_k 的样本点。 $K(x, x_k)$ 为核函数,

$$K(x, x_k) = \exp\left\{-\|x - x_k\|^2 / 2\sigma^2\right\}.$$

3.3 预测评价模型

为了对模型的预测结果进行评价, 本文选取四个指标如下: 均方根误差(RMSE)、相对均方误差(ERE)、归一化绝对误差(ENAE)、均等系数(EC, 拟合度)。4个评价指标公式为:

$$RMSE = \left\{ \frac{\sum_{t=1}^N [\hat{y}(t) - y(t)]^2}{N} \right\}^{\frac{1}{2}}, \quad (6)$$

$$ERE = \frac{\sum_{t=1}^N [\hat{y}(t) - y(t)]^2}{\sum_{t=1}^N y^2(t)}, \quad (7)$$

$$ENAE = \frac{\sum_{t=1}^N |\hat{y}(t) - y(t)|}{\sum_{t=1}^N y(t)}, \quad (8)$$

$$EC = 1 - \frac{\sqrt{\sum_{t=1}^N [\hat{y}(t) - y(t)]^2}}{\sqrt{\sum_{t=1}^N [\hat{y}(t)]^2} + \sqrt{\sum_{t=1}^N [y(t)]^2}}. \quad (9)$$

式(6)-(9)中 $\hat{y}(t)$ 是在 t 月降水量的预测值, $y(t)$ 是在 t 月降水量的实际值, N 为预测时长。RMSE 反映预测值对实际值的偏离程度, 取值越小预测精度越高; ERE 反映预测值对实际值的平均相对偏离程度, 取值越小预测精度越高; ENAE 将预测的平均绝对误差对实际的均值归一化, 取值越小预测精度越高; EC 反映预测值与真实值之间的拟合程度, 取值越大预测精度越高, 通常情况下, 若 $EC > 0.9$, 则说明该预测模型有较高的预测精度。

4 实例分析

选取郑州市 1979-2020 年逐月降水量数据作为研究对象, 按 85: 15 的比例划分训练集和测试集, 前 85% 的数据用于模型训练, 后 15% 的数据用于模型测试。

(1) 基于 VMD-SVR 的预测

利用 VMD 将原始时间序列分解为 8 个子序列, 分解结果如图 4 所示。

用 SVR 模型将分解出来的各分量进行预测, 并将各分量的预测结果叠加得到最终预测值, 其预测值与真实值对比结果如图 5 所示, 预测值和实际值较为一致。

(2) 不同数据不同方法的对比预测

对原始时间序列进行基于支持向量机 (SVM)、RBF 神经网络及随机森林 (RF) 预测, 其预测值与真实值对比结果如图 6 所示, 预测值与实际值相差较大。

通过 C-C 法计算得到混沌时间序列重构参数时间延迟为 3 和嵌入维数为 9, 根据重构参数将时间序列重构得输入变量为 9 维, 对相空间重构后的时间序列进行基于支持向量机 (SVM)、RBF 神经网络及随机森林 (RF) 的预测, 其预测值与真实值对比结果如图 7 所示, 预测值与实际值较原始时间序列相似, 但是整体相差较大。

计算三种数据类型对应的 SVR、RBF 神经网络和 RF 模型的预测精度得表 1, 由表可知相空间重构数据整体预测精度较原始时间序列的预测有所提升, 但提升不大。预测模型 RMSE 较高, ERE 和 ENAE 较大, 模型拟合度 EC 均小于 0.8, 模型预测精度较低。经 VMD 分解后的预测精度比原始序列数据和相空间重构数据有明显提升, RMSE 较低, ERE 和 ENAE 值较小, 模型拟合度 EC 均大于 0.9, 预测精度较高。

经过 VMD 分解的数据, 使用 RBF 神经网络和 RF 预测并与 VMD-SVR 对比, 由表 1 可知, VMD-SVR 模型的 RMSE 和 EC 表现优于 VMD-RBF 和 VMD-RF, 在降水量时间序列预测模型中精度更高, 三种方法对比结果如图 8 所示。

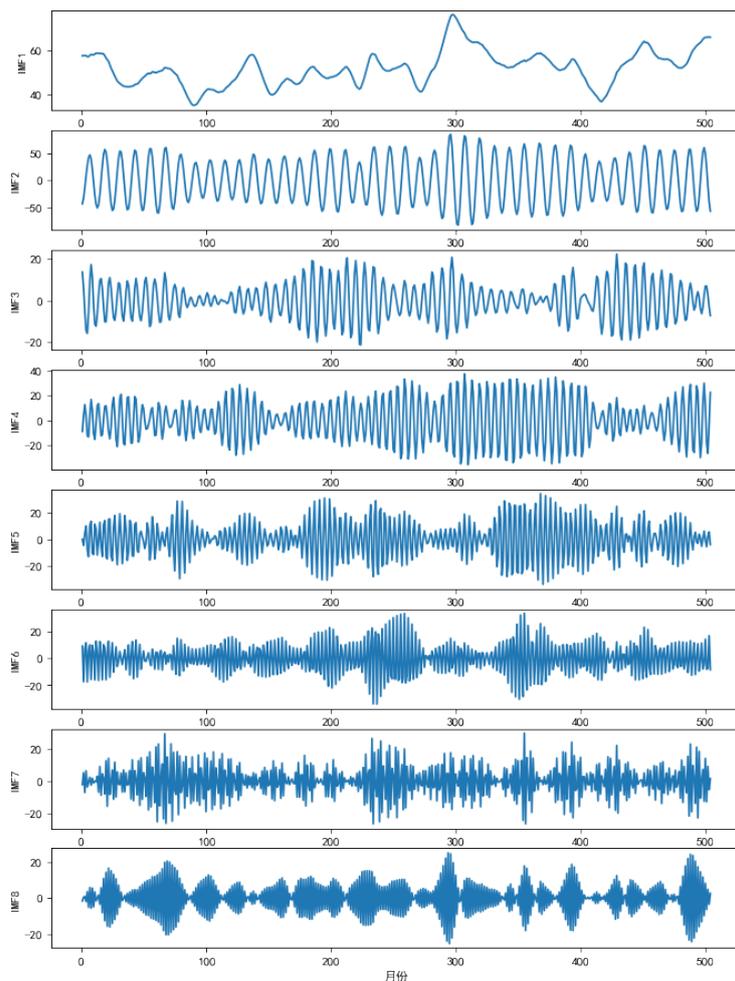


图 4 变分模态分解结果

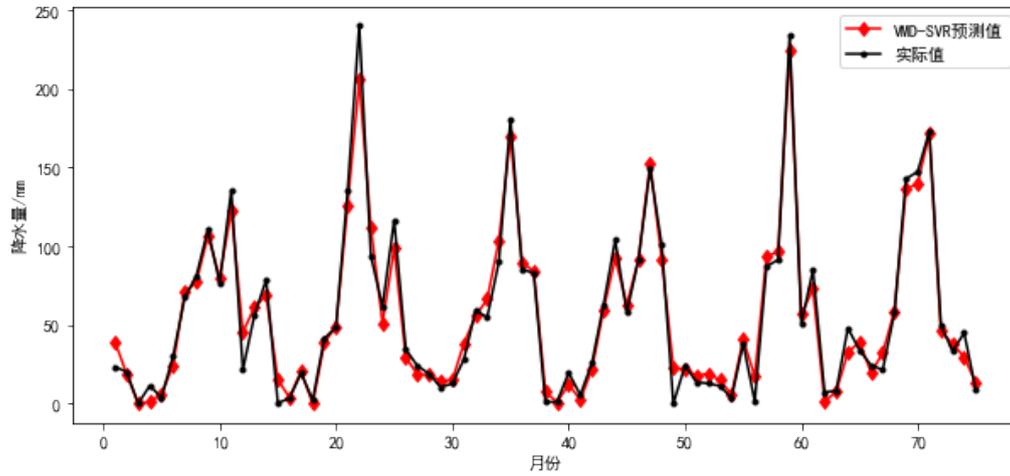


图5 基于 VMD-SVR 算法预测

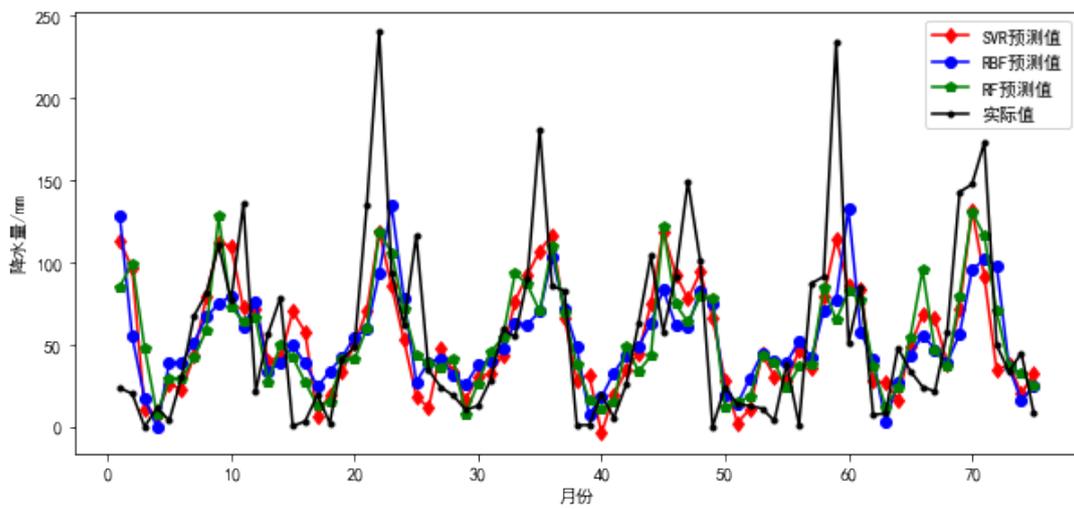


图6 基于原始时间序列的机器学习算法预测

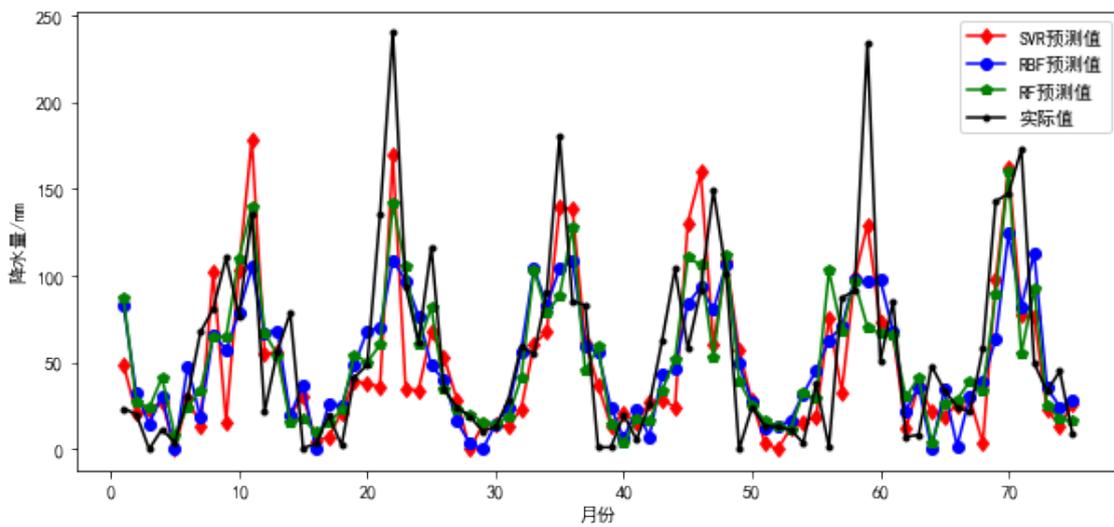


图7 基于相空间重构时间序列预测图

表 1 不同数据类型预测精度

数据类型	预测模型	RMSE	ERE	ENAE	EC
变分模态分解数据	VMD-SVR	9.41023	0.014438	0.123999	0.938852
	VMD-RBF	10.2251	0.017047	0.130240	0.933499
	VMD-RF	12.6487	0.026086	0.162565	0.917324
原始序列数据	SVR	41.5312	0.281235	0.539854	0.708398
	RBF	47.0583	0.361071	0.603961	0.659424
	RF	43.9981	0.315636	0.554241	0.686589
相空间重构数据	SVR	40.2471	0.264112	0.522076	0.720776
	RBF	40.4689	0.267032	0.503904	0.709380
	RF	42.1748	0.290018	0.501571	0.702684

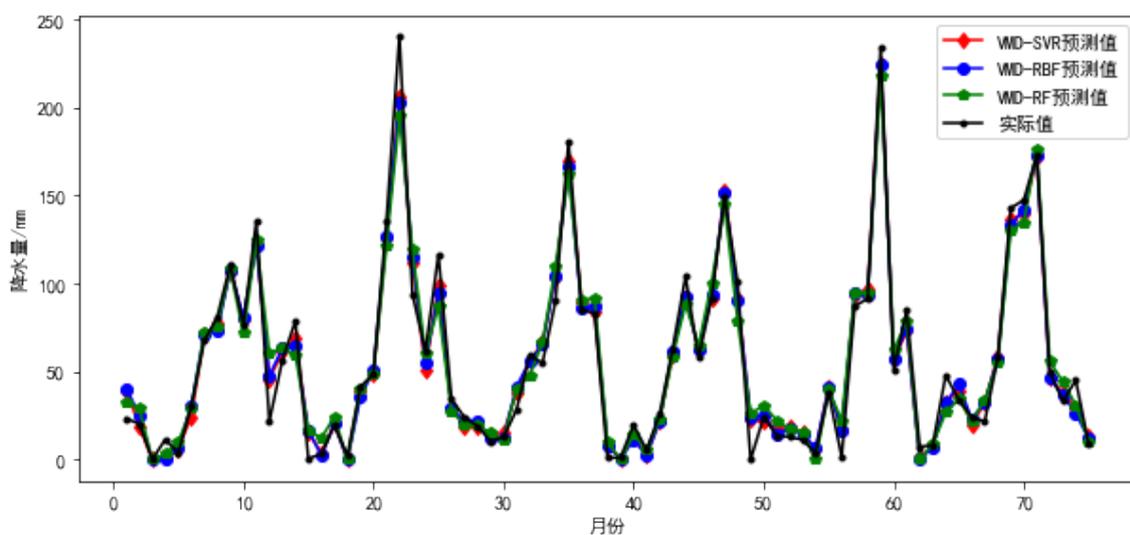


图 8 基于 VMD 的机器学习算法预测

5 结论

本文在 SVR 的基础上, 构建了 VMD-SVR 降水量预测模型并应用于郑州市 1979-2020 年逐月降水量的预测。同时, 运用机器学习算法对降水量原始数据、相空间重构数据和变分模态分解数据进行预测, 研究发现, 对原始降水量时间序列进行预测时, SVR、RBF 神经网络和 RF 的 RMSE 较高, ERE 和 ENAE 值偏大, EC 小于 0.7, 模型预测精度较低; 对混沌时间序列相空间重构的降水量数据预测, 较原始降水量时间序列预测精度有所提高, 但预测结果精度仍有待提高; 对变分模态分解的降水量时间预测时, 三种预测模型 RMSE 明显降低, ERE 和 ENAE 值偏小, EC 均大于 0.9, 说明变分模态分解更适合降水量序列的预测。基于变分模态分解后的 SVR 预测方法 $EC=0.9388$, $RMSE=9.41023$, 较 VMD-RBF 和 VMD-RF 预测方法误差小, 预测精度高, 说明本文构建的 VMD-SVR 模型应用到降水量预测时有较好的预测效果, 该方法可以进一步拓展到其他非线性序列的预测应用中。

参考文献

- [1] 尹宜舟, 高歌, 王国复. 气象灾害的灾体模型及其初步应用[J]. 气象, 2019, 45(10):1439-1445.
- [2] 包红军, 曹勇, 曹爽, 王蒙. 基于短时临近降水集合预报的中小河流洪水预报研究[J]. 河海大学学报(自然科学版) 2021, 49(3):197-203.

- [3] 张丽婷, 李鹏飞, 庞文静, 惠雯, 秦孟晟. 基于季节性自回归积分滑动平均与深度学习长短期记忆神经网络的降水量预测[J]. 科学技术与工程, 2022, 22(09):3453-3463.
- [4] 迟道才, 王子凰, 陈涛涛, 许杏娟, 张瑞. ARIMA 和蒙特卡洛方法在预测降水量中的应用[J]. 沈阳农业大学学报, 2015, 46(02):187-191.
- [5] 余霖, 吕鑫, 周思琪, 刘璇. 多分支的降水量概率预测模型研究[J]. 计算机科学, 2017, 44(10):222-227.
- [6] 郝慧慧, 朱涵钰. 改进灰色波形预测方法在降水量预测中的应用[J]. 节水灌溉, 2021(09):41-44+50.
- [7] BYUNG S K, SYED Z H, GYEWOON C. Evaluation of temporal-spatial precipitation variability and prediction using seasonal ARIMA model in Mongolia[J]. KSCE Journal of Civil Engineering, 15, 917-925 (2011).
- [8] PRIYA N, ASHOKE B, SUMANA S, KAMNA S. Trend analysis and ARIMA modelling of pre-monsoon rainfall data for western India[J]. Comptes Rendus Geoscience, 2013, 345(1):22-27.
- [9] 吴林川, 孙婴婴. 加权马尔科夫链在榆林市降水量预测中的应用[J]. 人民长江, 2017, 48(S1):82-84+100.
- [10] 贺佳佳, 陈凯, 陈劲松, 徐文文, 唐历, 刘军. 一种多时间尺度 SVM 局部短时临近降雨预测方法[J]. 气象, 2017, 43(04):402-412.
- [11] 贺玉琪, 王栋, 王远坤. BRR-SVR 月降水量预测优化模型[J]. 水利学报, 2019, 50(12):1529-1537.
- [12] 甄亿位, 郝敏, 陆宝宏, 左建, 刘欢. 基于随机森林的中长期降水量预测模型研究[J]. 水电能源科学, 2015, 33(06):6-10.
- [13] 卢维学, 吴和成, 万里洋. 基于融合随机森林算法的 PLS 对降水量的预测[J]. 统计与决策, 2020, 36(18):27-31.
- [14] 吴群, 陈晓辉, 李东普, 赵琴. 改进 RBF 神经网络在降水量预测中的应用[J]. 信阳师范学院学报(自然科学版), 2011, 24(02):268-271.
- [15] 舒涛, 路昊天, 曹景轩, 叶唐进, 陶伟, 付润艺, 李豪. 基于混沌理论的降水量预测方法研究[J]. 灌溉排水学报, 2022, 41(03):83-91.
- [16] MANLIO D D, MOHAMMAD A G, OLEG M, DINA M, HAKIMEH A. Chaos and reproduction in sea level[J]. Applied Mathematical Modelling, 2013, 37(6):3687-3697.
- [17] CHAITANYA D, ALI Y. Flood prediction using Time Series Data Mining[J]. Journal of Hydrology, 2007, 333(2-4):305-316.
- [18] 孙望良, 周建中, 彭利鸿, 徐占兴, 莫莉, 胡斯曼, 何飞飞. DFA-VMD-LSTM 组合日径流预测模型研究[J]. 水电能源科学, 2021, 39(03):12-15.
- [19] 徐冬梅, 王亚琴, 王文川. 基于 VMD-TCN 的月降水量预测模型[J]. 水文, 2022, 42(02):13-18.
- [20] WOLF A, SWIFT J B, SWINNEY H L, VASTANO J A. Determining Lyapunov exponents from a time series[J]. Physica D: Nonlinear Phenomena, 1985, 16(3):285-317.
- [21] 李曼. 基于支持向量机的混沌时间序列预测[D]. 北方民族大学, 2021.

版权声明: ©2023 作者与开放获取期刊研究中心(OAJRC)所有。本文章按照知识共享署名许可条款发表。

<http://creativecommons.org/licenses/by/4.0/>



OPEN ACCESS