

基于TVF-EMD与SVR组合的月降水量预测

赖奇风,曾九汉

(赣州市水利电力勘测设计研究院有限公司,江西 赣州 341000)

摘要:准确的月降水预测对水资源优化配置与科学管理具有重要意义。但受气候变化与人类活动的影响,月降水序列具有非线性和非平稳性特征,使得传统的线性统计模型或单一机器学习模型对月降水序列进行预测具有较大的误差。为进一步提升月降水预测精度,文章提出一种结合时变滤波经验模态分解(Time Varying Filter-based Empirical Mode Decomposition, TVF-EMD)与支持向量机回归(Support Vector Regression, SVR)的组合预测模型。以江西省赣州市赣县气象站月降水序列为研究对象开展实例研究,结果表明:基于“分解-预测-重构”框架的TVF-EMD-SVR组合模型的月降水预测结果纳什效率系数达0.93。所提出的组合模型预测性能显著优于多元线性回归、SVR等单一模型以及EMD-SVR组合模型,验证了TVF-EMD-SVR组合模型为月降水预测的有效方法,可为区域水库调度及农业生产等决策环节,提供精度更高、可靠性更强的月降水预测结果。

关键词:月降水序列;TVF-EMD;SVR;组合预测模型;江西赣州

中图分类号:TV124 **文献标识码:**A **文章编号:**1001-9235(XXXX)XX-0001-10

江西赣州是赣江的发源地,同时也是珠江支流东江的重要源头之一。该地区河网密布,水系发达,降水的时空变化决定着流域内水库蓄泄调度及农业灌溉保障,是影响区域水资源安全的关键因素^[1-2]。赣州属亚热带季风性湿润气候,四季分明,降水总量充沛,但年内分配高度不均,汛期降水集中,且易发洪涝,非汛期则水资源紧张,供需矛盾突出。与此同时,年际降水波动显著,进一步加剧了水资源供给的不确定性,不仅对以降水为主要补给来源的中小型水库调度构成持续压力,也严重制约了农业生产中的水资源利用效率。因此,发展高精度的月降水预测技术,不仅是优化水库兴利除害调度、提升农业用水配置效率的迫切需求,更是保障区域水资源安全与粮食生产稳定的关键支撑^[3]。

传统的降水预测模型,如自回归模型、滑动平均模型和多元线性回归(Multivariable Linear Regression, MLR)等,通常基于时间序列满足线性与平稳性的假设构建。然而,在气候变化及人类活动

的双重作用下,月降水序列普遍呈现非线性与非平稳特征,导致传统模型在实际预测中适用性较差,预测精度有限^[4]。为捕捉月降水序列中的非线性特征,以人工神经网络、支持向量机回归(Support Vector Regression, SVR)为代表的机器学习方法被广泛应用于水文预测中^[5]。其中,SVR模型通过核函数映射将低维非线性问题转化为高维线性问题求解,在小样本条件下展现出比人工神经网络更好的性能^[6]。同时,其在计算复杂度上显著低于长短期记忆网络等深度学习模型,在训练与预测速度上具有明显优势^[7]。

然而,SVR等单一预测模型在面对非平稳水文序列时,预测能力仍存在明显局限^[8]。为进一步提升对非平稳序列的建模能力,采用“分解-预测-重构”的两阶段框架已成为当前主流研究范式。该框架核心在于,先通过模态分解方法对原始序列进行平稳化预处理,再将得到的相对平稳的子序列输入预测模型^[9]。在此框架下,以经验模态分解

(Empirical Mode Decomposition, EMD)为代表的自适应分解方法因其无需预设基函数、在水文时间序列平稳化预处理中得到了广泛的应用^[10]。然而, EMD存在模态混叠、端点效应等固有缺陷^[11]。为此, 一系列基于EMD的改进方法被相继应用于水文领域, 例如互补集合经验模态分解(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, CEEMDAN)通过添加自适应白噪声有效抑制了模态混叠, 但CEEMDAN在处理水文序列时仍可能产生残余噪声, 为后续预测模型的输入引入干扰^[12-13]。

时变滤波经验模态分解(Time Varying Filter based Empirical Mode Decomposition, TVF-EMD)通过引入基于局部截止频率的自适应时变滤波器实现序列分解, 在理论上能更有效地抑制模态混叠^[14-15]。在处理非平稳水文序列时, TVF-EMD相较于EMD、CEEMDAN等方法, 能够为后续预测模型提供质量更高的输入。然而, 目前将TVF-EMD与SVR相结合, 并系统评估其在月降水预测中综合性能的研究仍较为缺乏^[16]。

因此, 本研究旨在结合TVF-EMD处理非平稳序列的能力与SVR在非线性序列中的建模优势, 构建TVF-EMD-SVR组合预测模型。将该模型应用于江西省赣州月降水序列预测中, 通过与MLR、SVR单一预测模型以及EMD-SVR组合预测模型进行对比, 验证TVF-EMD-SVR组合模型在提升月降水预测精度的适用性及有效性, 以期为非平稳、非线性月降水序列的精准预测提供新方法。

1 研究方法

1.1 模态分解方法

1.1.1 EMD

EMD将时间序列分解为一系列固有模态分量(Intrinsic Mode Function, IMF)和一个残余项(Residual, RES)。这些IMF反映了时间序列中不同尺度的波动特征, 每个IMF都是一种包含单一频率成分的函数。EMD实现月降水序列分解的具体步骤如下^[11]:

a) 提取月降水序列 $P(t)$ 的极大值点和极小值

点, 并分别连接形成上、下包络线, 求得上下包络线均值。

$$\alpha(t) = \frac{e_{\text{up}}(t) + e_{\text{low}}(t)}{2} \quad (1)$$

式中: $e_{\text{up}}(t)$ 、 $e_{\text{low}}(t)$ 为上、下包络线; $\alpha(t)$ 为上、下包络线均值。

b) 原始月降水序列 $P(t)$ 减去 $\alpha(t)$, 得到新序列 $\omega(t)$ 。若 $\omega(t)$ 满足极值点和过零点数目相差不超过一个, 且任意时刻, 局部极大值点构成的上包络线和局部极小值点构成的下包络线的均值应为零这两个条件, 则 $\omega(t)$ 即作为分解后的第一个子序列IMF1; 若不满足, 将 $\omega(t)$ 作为原始序列, 重复上述步骤(1)、(2), 直到 $\omega(t)$ 满足条件。 $\omega(t)$ 计算见式(2):

$$\omega(t) = P(t) - \alpha(t) \quad (2)$$

c) 通过上述步骤得到IMF1, 利用 $P(t)$ 减去IMF1, 得到剩余分量 $R(t)$

$$R(t) = P(t) - \text{IMF1} \quad (3)$$

d) 将剩余分量 $R(t)$ 作为新原始序列 $P(t)$ 重复步骤a—d, 当满足剩余分量小于预定值或为单调函数时, 分解结束。最终分解结果为:

$$P(t) = \sum_{i=1}^n \text{IMFi} + R(t) \quad (4)$$

1.1.2 TVF-EMD

TVF-EMD利用瞬时幅值和瞬时频率, 自适应设计局部截止频率, 对给定序列进行时变滤波, 将其分为局部高频分量和局部低频分量, 得到IMF。TVF-EMD计算过程如下^[14-15]:

a) 对月降水序列 $P(t)$ 进行希尔伯特变换, 得到 $S(t)$ 。由 $P(t)$ 和 $S(t)$ 计算瞬时幅值 $\text{Amp}(t)$ 和瞬时相位 $\lambda(t)$:

$$\text{Amp}(t) = \sqrt{P(t)^2 + S(t)^2} \quad (5)$$

$$\lambda(t) = \arctan \frac{P(t)}{S(t)} \quad (6)$$

b) 确定瞬时幅值 $\text{Amp}(t)$ 的局部最大值 $\text{Amp}_{\text{max}}(t)$ 和局部最小值 $\text{Amp}_{\text{min}}(t)$ 。然后对 $\text{Amp}_{\text{max}}(t)$ B样条插值, 对 $\text{Amp}_{\text{min}}(t)$ 插值出最大点集及最小点集, 得到曲线 $\text{cur}_1(t)$ 和 $\text{cur}_2(t)$, 计算 $\eta_1(t)$

和 $\eta_2(t)$:

$$\eta_1(t) = \frac{cur_1(t) + cur_2(t)}{2} \quad (7)$$

$$\eta_2(t) = \frac{cur_1(t) - cur_2(t)}{2} \quad (8)$$

c) 对 $\lambda'(t_{\max})Amp^2(t_{\max})$ 进行插值得到 $\beta_1(t)$ 、对 $\lambda'(t_{\min})Amp^2(t_{\min})$ 进行插值得到 $\beta_2(t)$ 。计算瞬时频率分量 $\lambda'_1(t)$ 、 $\lambda'_2(t)$:

$$\lambda'_1(t) = \frac{\beta_1(t)}{2\eta_1^2(t) - 2\eta_1(t)\eta_2(t)} + \frac{\beta_2(t)}{2\eta_1^2(t) + 2\eta_1(t)\eta_2(t)} \quad (9)$$

$$\lambda'_2(t) = \frac{\beta_1(t)}{2\eta_2(t) - 2\eta_1(t)\eta_2(t)} + \frac{\beta_2(t)}{2\eta_2(t) + 2\eta_1(t)\eta_2(t)} \quad (10)$$

d) 为解决间歇问题, 重新调整区域截止频率 $\lambda'_{bis}(t)$

$$\lambda'_{bis}(t) = \frac{\lambda'_1(t) + \lambda'_2(t)}{2} \quad (11)$$

e) 计算 $\delta(t) = \cos\left[\int \lambda'_{bis}(t)d(t)\right]$, 以 $\delta(t)$ 的极值为节点, 构造 B 样条曲线作为近似滤波器, 利用该滤波器对月降水序列 $P(t)$ 进行滤波, 逼近结果为 $m(t)$ 。

f) 根据停止准则 $\sigma(t)$, 判断 $\sigma(t)$ 是否满足 $\sigma(t) < r$, 若满足则 $S(t)$ 为 IMF。若不满足, 重复步骤 (1)–(5)。停止准则 $\sigma(t)$ 计算公式为:

$$\sigma(t) = \frac{B_{Loughlin}(t)}{\lambda_{avg}(t)} \quad (12)$$

式中: $B_{Loughlin}(t)$ 为双分量序列的 Loughlin 瞬时带宽; $\lambda_{avg}(t)$ 为单分量瞬时频率的加权平均值; r 为带宽阈值。

1.2 预测模型

1.2.1 MLR

MLR 是一种基于最小二乘法原理构建的经典线性预测模型, 模型一般形式为式 (13):

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_n x_n + \varepsilon \quad (13)$$

式中: y 为因变量, 在本研究为月降水量; β_0 为偏置项; β_i 为权重项; x_i 为自变量, 即模型的输入; ε 为模

型误差项。

1.2.2 SVR

SVR 是通过非线性映射将月降水序列映射到高维空间, 然后在高维空间中进行线性回归^[17]。

SVR 的回归函数表示为式 (14):

$$f(x) = w \times \phi(x) + b \quad (14)$$

式中: w 为权重向量; b 为偏置项, $\phi(x)$ 为将输入向量 x 投影到高维特征空间的函数, 从而可以在高维空间中进行线性建模。

为了得到合适的 SVR 函数, 可以将回归问题看作如下的凸优化问题:

$$\min \frac{\|w\|^2}{2} + C \sum_{i=t+1}^n (\xi + \xi^*) \quad (15)$$

式中: C 为惩罚因子; ξ, ξ^* 为松弛变量。

SVR 提供了使用各种核函数的灵活性, 包括多项式核、线性核和径向基函数 (Radial Basis Function, RBF)。本研究选择 RBF 内核, 因为它与其他核函数相比具有更低的预测误差。

$$K(x_i, x_j) = \exp\left(\frac{-\|x_i - x_j\|^2}{2g^2}\right) \quad (16)$$

式中, g 为高斯核的宽度。

1.2.3 组合预测模型的构建

“分解-预测-重构”建模策略首先应用 EMD 与 TVF-EMD 对原始月降水序列进行分解, 得到一系列相对平稳的子序列 (IMF1, IMF2, ...)。其次, 分别构建独立的 SVR 模型, 得到各子序列预测结果。最后, 对所有子序列的预测结果进行加和, 重构得到 EMD-SVR 与 TVF-EMD-SVR 两种组合模型的最终月降水量预测结果。本文所构建的月降水组合预测模型具体流程见图 1。

1.2.4 模型输入的确

采用自相关函数 (Autocorrelation Function, ACF) 和偏自相关函数 (Partial Autocorrelation Function, PACF) 对月降水序列的滞后阶数进行分析, 确定模型的输入。ACF 是检验序列的自相关系数, 当月降水序列为 $P(t) = \{t_1, t_2, \dots, t_n\}$, ACF 检验的是 $P(t)$ 与 $P(t-h)$ 间的相关性, 其中 h 为滞后阶




图1 组合预测模型建模流程

Fig. 1 Modeling process of the combined forecasting model

数。滞后 h 阶后 ACF 计算公式为式(17):

$$\text{ACF}(h) = \frac{\sum_{i=h+1}^n (t_i - \bar{t})(t_{i-h} - \bar{t})}{\sum_{i=1}^n (t_i - \bar{t})^2} \quad (17)$$

式中, \bar{t} 为月降水序列的均值。

在控制中间滞后项 ($P(t-1), P(t-2), \dots, P(t-h+1)$) 的影响后, 度量 $P(t)$ 与 $P(t-h)$ 的直

接相关性, 即为 PACF 结果。

图2展示了月降水序列 ACF、PACF 计算结果。ACF 在滞后 12、24、36 个月处出现显著峰值, 揭示了月降水序列存在 12 个月的周期。PACF 在滞后 12 个月后就迅速衰减并基本落入 95% 置信区间内, 这表明当前月的降水主要受过去 12 个月内(尤其是前 12 个月)降水状态的影响^[18-19]。因此选择前 12 个月降水作为输入, 预测第 13 个月的降水。




图2 月降水序列 ACF、PACF 计算结果

Fig. 2 The ACF and PACF calculation results of the monthly precipitation series

1.3 模型评价指标

为定量评价所提出的组合模型的预测性能, 本文采用纳什效率系数 (Nash-Sutcliffe Efficiency, NSE) 平均绝对误差 (Mean Absolute Error, MAE) 和均方根误差 (Root Mean Square Error, RMSE) 3 个评价指标对各模型的预测结果进行检验^[20-21]。各指标的计算式见式(18)–(20):

$$\text{NSE} = 1 - \frac{\sum_{i=1}^n (P_{o,i} - P_{p,i})^2}{\sum_{i=1}^n (P_{o,i} - \bar{P}_o)^2} \quad (18)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |P_{o,i} - P_{p,i}| \quad (19)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_{o,i} - P_{p,i})^2} \quad (20)$$

式中: $P_{o,i}$ 为实测值, mm; $P_{p,i}$ 为预测值, mm; \bar{P}_o 为实测值的平均值, mm; n 为月降水序列长度。

2 实例分析

2.1 月降水序列及其特征分析

赣县气象站 (编号 57993) 是赣州市重要的气象点, 站点 1951—2020 年月降水序列如图 3 所示。由图 3 可得, 月降水序列呈现出明显的非线性。图 4 进一步展示了该时段内月降水的年内分配特征与年际变化趋势。分析表明, 研究区月降水量在年内分配上极不均衡, 降水主要集中于汛期 (4—9 月),

该时期降水量约占全年总量的 65.78%;非汛期(1—3月及10—12月)降水相对稀少,仅占34.22%^[22]。这种季节性的集中分布构成了月降水序列重要的非平稳特征之一。在年际尺度上,月降水的滚动均值与滚动方差(24个月窗口)呈现出明显的动态变化。多年平均月降水量为120.30 mm,而滚动均值在81.10~167.00 mm波动,总体呈下降

趋势,变化率为-0.38 mm/10 a。月降水序列的方差为 $8.48 \times 10^3 \text{mm}^2$,滚动方差的最大值与最小值分别较均值变化+111.28%和-63.23%,其长期变化趋势线的斜率为-2.06 mm²/月。两个统计量的非恒定共同证实了月降水序列具有典型的非平稳性特征^[23]。




图3 1951—2020年逐月降水序列

Fig. 3 Monthly precipitation series from 1951 to 2020

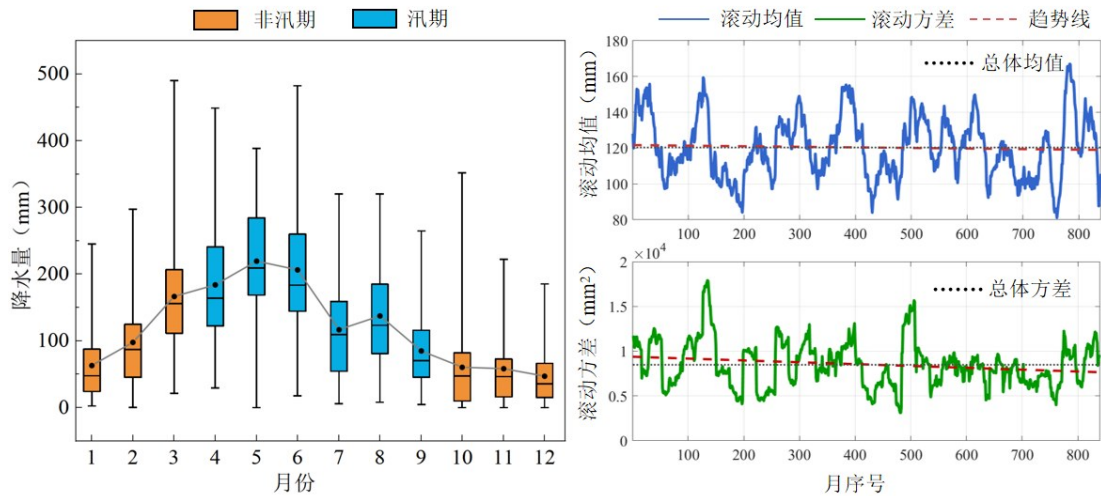


图4 月降水年内分配特征及均值、方差变化趋势

Fig. 4 Intra-annual distribution characteristics and trends in mean and variance of monthly precipitation

2.2 月降水序列分解结果

为验证TVF-EMD方法的有效性,本研究分别采用EMD与TVF-EMD方法对月降水序列进行分解。其中,EMD为一种自适应分解方法,其分解得到的分量数量无需预设。月降水序列经EMD分解后的结果见图5a,由结果可得,月降水序列被分解为8个IMF和1个RES。TVF-EMD方法需自定义子序列的分解数量,为保持方法间可比性,避免因

分解数量差异影响预测结果,本研究将TVF-EMD的分解数量设置为与EMD一致,即同样分解为8个IMF和1个RES,其分解结果见图5b。由图5可得,从IMF1到RES,各分量的振动频率依次递减。

2.3 月降水预测结果分析

本研究构建了MLR和SVR两种单一月降水预测模型,以及EMD-SVR和TVF-EMD-SVR两种组合月降水预测模型。其中1951—1999年为训练期,

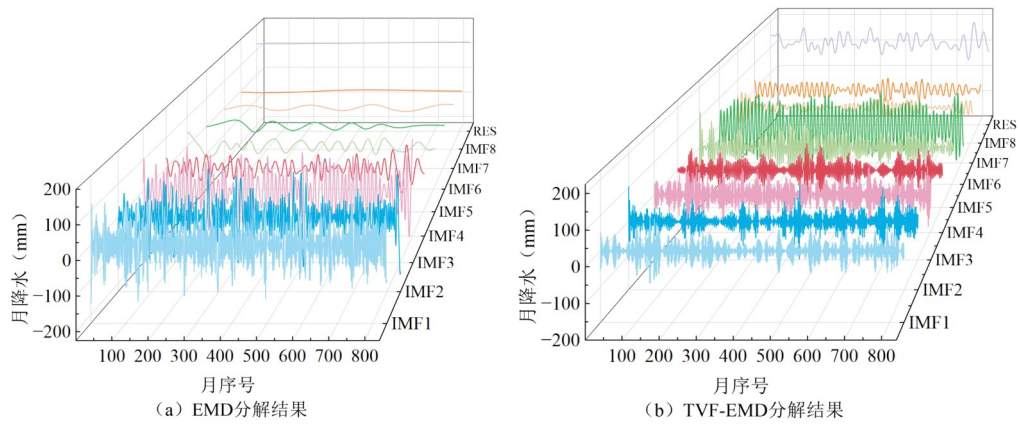


图5 月降水序列分解结果

Fig. 5 Decomposition results of the monthly precipitation series

2000–2020年为测试期,各模型的预测结果如图6所示。结果表明,TVF-EMD-SVR组合模型在月降水预测中能够更准确地反映实际降水的变化过程,其预测结果与实测值最为接近,尤其在月降水序列峰值处的预测误差最小。图7给出了各模型月降水量预测结果的散点图。当预测结果的皮尔逊相关系数(Pearson Correlation Coefficient, PCC)越接近于1,说明模型的预测精度越高。由4个模型的预测结果

可得,在训练期SVR、EMD-SVR、TVF-EMD-SVR模型相较于MLR模型,PCC分别提升了10.17%、37.29%、67.80%;在测试期各模型相较于MLR模型,PCC分别提升了54.76%、92.86%、133.33%。因此,各模型预测结果的拟合效果从优到劣排序为:TVF-EMD-SVR模型>EMD-SVR模型>SVR模型>MLR模型。

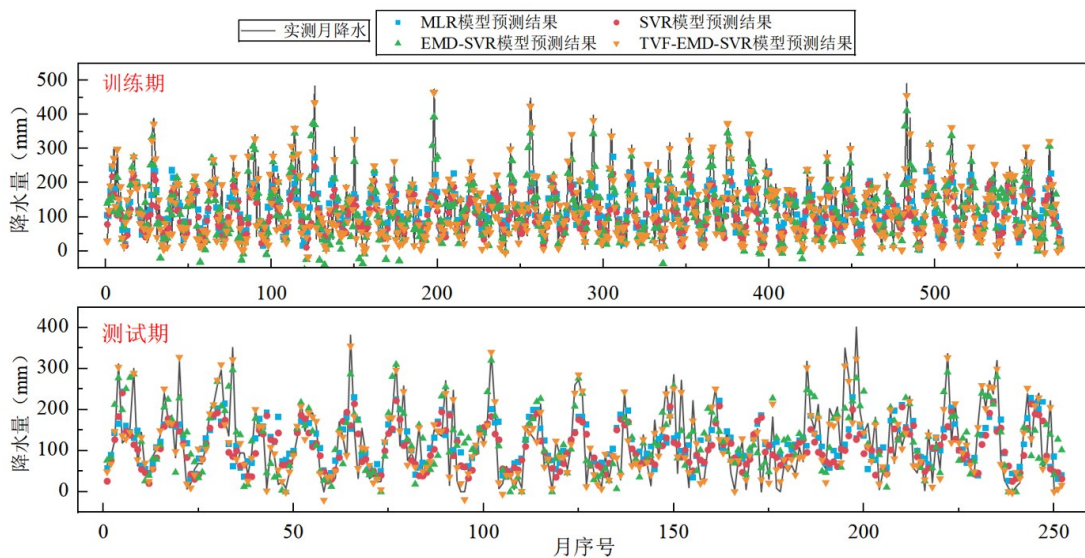


图6 不同模型月降水序列预测结果

Fig. 6 Prediction results of monthly precipitation series from different models

表1进一步给出了各模型月降水预测精度的评估结果。对比单一模型MLR与SVR的预测表现可

以看出,SVR模型的预测精度更高,其NSE在训练期和测试期均有提升,而MAE和RMSE则均有所降

低。这是因为月降水序列具有显著的非线性特征, MLR 模型主要局限于捕捉序列中的线性关系, 在处理非线性降雨序列时存在不足, 因此预测精度最

低。而 SVR 模型通过核函数将原始降水序列映射到高维空间, 能够有效捕捉非线性关系, 从而在预测精度上较 MLR 有所提高。

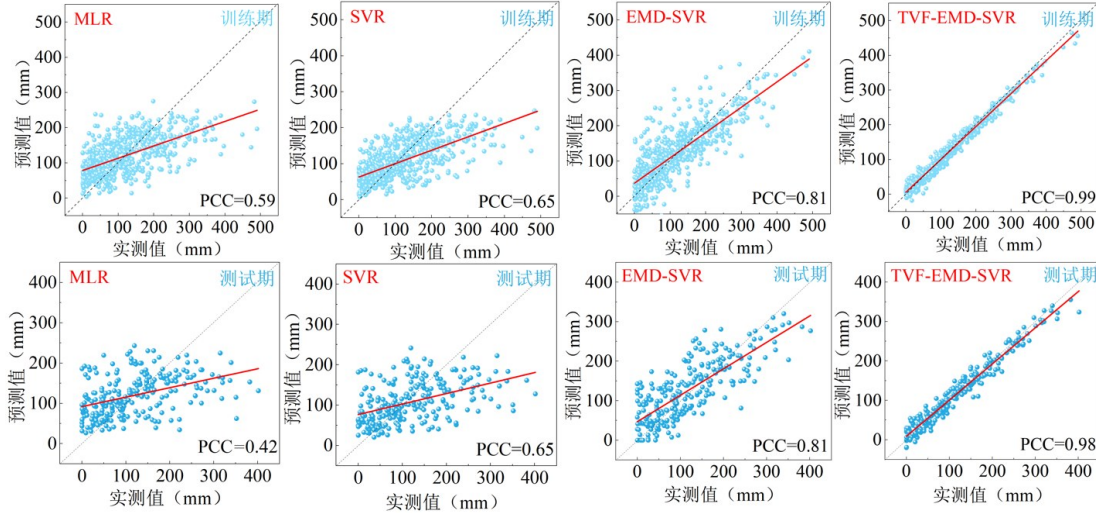


图7 不同模型预测结果散点图

Fig. 7 Scatter plots of prediction results from different models

然而, 单一 SVR 模型的预测精度仍不理想, 其 NSE 仅为 0.19。这是由于月降水序列受气候变化等因素影响, 表现出明显的非平稳性, 使得单一预测模型难以实现高精度预测。为此, EMD-SVR 模型在 SVR 基础上引入 EMD 方法, 将月降水序列分解为多个相对平稳的子序列, 通过为各子序列建立独立的预测模型, 最终重构得到优化后的预测结果。预测结果显示, 与单一 SVR 模型相比, EMD-SVR 在训练期和测试期的 NSE 分别提升 289.47%、92.50%, MAE 和 RMSE 在训练期分别降低 22.35%、24.46%; 在测试期分别降低 25.76%、29.39%, 表明“分解-预测-重构”的组合模型有效提高预测精度。

尽管 EMD-SVR 模型在一定程度上改善了预测性能, 但其仍受 EMD 方法自身存在的模态混叠现象限制, 制约了精度的进一步提升。TVF-EMD 方法相较于 EMD 能够缓解该问题, 因此 TVF-EMD-SVR 模型在训练期和测试期的 NSE 继续提高 23.38%、25.68%, MAE 与 RMSE 在训练期分别降低 73.95%、74.83%, 在测试期分别降低 67.83%、67.67%, 显示出最优的综合预测能力。

表1 不同模型预测性能评估结果

Tab. 1 Performance evaluation of predictions from different models

模型	NSE		MAE/mm		RMSE/mm	
	训练期	测试期	训练期	测试期	训练期	测试期
MLR	0.35	0.15	58.21	61.40	75.22	81.56
SVR	0.40	0.19	51.90	59.62	72.11	79.68
EMD-SVR	0.77	0.74	40.30	44.26	54.47	56.26
TVF-EMD-SVR	0.95	0.93	10.50	14.24	13.71	18.19

进一步讨论 EMD-SVR 与 TVF-EMD-SVR 模型预测误差来源, 对比结果差异, 图 8 给出了 EMD-SVR 与 TVF-EMD-SVR 模型对分解后所得各子序列独立预测误差。由图 8 可得, EMD-SVR 模型的预测误差主要来源于 IMF1、IMF2 的预测。这是因为, 由图 5 月降水序列分解结果可得, IMF1-IMF4 振动频率较高, 子序列特征较为复杂。TVF-EMD-SVR 模型主要预测优势主要来源于对子序列 IMF1-IMF4 预测误差显著降低, 相较于 EMD-SVR 模型的 IMF1-IMF4 的预测, 测试期 MAE 分别降低 92.18%、

62.91%、20.50%、67.06%，RMSE 分别降低 91.86%、61.97%、41.34%、74.96%。产生上述现象的原因在于这一显著改进的原因在于 TVF-EMD 方法本身的核心优势。与传统的 EMD 方法使用固定筛选准则不同，TVF-EMD 引入了时变滤波技术，能够自适应地根据序列局部特征来分离分量。这种

机制使其能更精准地界定高频成分(如 IMF1-IMF4)，有效缓解了 EMD 中常见的模态混叠问题。因此，经 TVF-EMD 分解得到的高频序列特征更平稳，从而显著降低了 SVR 模型对高频分量进行拟合和预测的难度，最终大幅提升了预测精度。

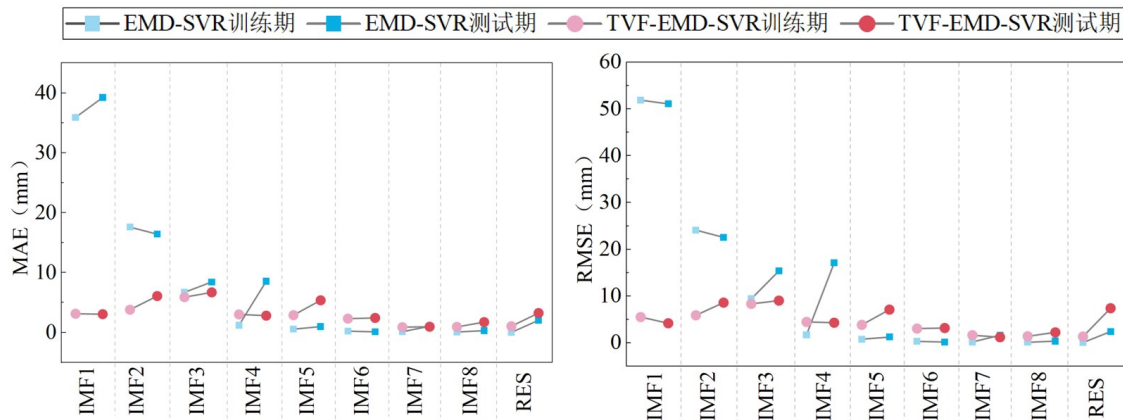


图8 各子序列预测误差

Fig. 8 Prediction errors of each subseries

但 TVF-EMD-SVR 模型对 IMF5 至 RES 等低频分量的预测误差略高于 EMD-SVR 模型。这主要归因于两种方法在分解低频信号时的特性差异:EMD 所获得的低频子序列(如 IMF8 与 RES)振动频率更低,且多数呈现单调或近似单调的特征,其平缓的变化趋势更易于 SVR 模型捕捉与拟合。相比之下,TVF-EMD 在分解过程中通过时变滤波保留了更多的局部波动信息,使得其低频分量仍具有一定的高频振荡,序列复杂度相对较高,从而对 SVR 模型的预测能力提出了更高要求,在一定程度上增加了拟合难度。

3 结论

本研究针对月降水序列的非线性、非平稳特征,构建了 TVF-EMD-SVR 组合预测模型,以江西省赣州市赣县气象站的长时序月降水序列为研究对象进行实例分析与性能评估,主要结论如下:

a)针对非平稳月降水序列,“分解-预测-重构”框架展现出明确的优越性。研究表明,SVR 等单一模型虽能捕捉月降水序列中的非线性关系,但其预

测性能受序列非平稳性的制约仍存在明显局限。通过引入模态分解方法对原始序列进行平稳化预处理,可提升模型预测精度。

b)通过对不同模态分解方法的应用对比分析可知,TVF-EMD 的性能显著优于传统 EMD 方法。TVF-EMD 通过自适应时变滤波机制,能够为后续预测模型提供更高质量的输入。预测结果表明,基于 TVF-EMD 分解的 SVR 模型 NSE 高达 0.93,其预测精度显著优于 EMD-SVR 模型及其他对照模型,验证了 TVF-EMD 在月尺度降水预测中的优越性与有效性。

c)本研究提出的 TVF-EMD-SVR 组合预测模型,在月尺度降水预测中显著提升了预测精度。该模型有效耦合了 TVF-EMD 在处理非平稳序列方面的优势与 SVR 在非线性序列中的建模优势,能够为区域水资源管理提供更为可靠的科学依据与技术支持。

参考文献:

- [1] 吴珊珊, 黄彩婷. 基于REOF方法的江西省6月降水趋势分区预测 [J]. 气象与减灾研究, 2015, 38 (1): 8-15.
Wu Shanshan, Huang Caiting. Prediction of partition precipitation trends of Jiangxi in June based on REOF [J]. Meteorology and Disaster Reduction Research, 2015, 38 (1): 8-15. (in Chinese)
- [2] 张超美, 宋进波, 章毅之, 等. 基于GCM模式预报的江西汛期降水降尺度预测模型 [J]. 气象与减灾研究, 2017, 40 (3): 171-177.
Zhang Chaomei, Song Jinbo, Zhang Yizhi, et al. A downscaling forecast model for precipitation in flood season over Jiangxi Province based on GCM system [J]. Meteorology and Disaster Reduction Research, 2017, 40 (3): 171-177. (in Chinese)
- [3] EBRAHIMI H. A novel evidential uncertainty framework for hybrid models in rainfall simulation [J]. Water Resources Management, 2026, 40 (2). DOI: 10.1007/s11269-025-04386-1.
- [4] Tao Lizhi, He Xinguang, Li Jiajia, et al. A multiscale long short-term memory model with attention mechanism for improving monthly precipitation prediction [J]. Journal of Hydrology, 2021, 602. DOI:10.1016/j.jhydrol.2021.126815
- [5] TADAYON A, NAZARI M, KERACHIAN R. Enhancing long-lead rainfall forecasting in data-scarce large watersheds using multi-model fusion [J]. Journal of Hydrology: Regional Studies, 2025, 62. DOI:10.1016/j.ejrh.2025.102936.
- [6] 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.
He Yuqi, Wang Dong, Wang Yuankun. BRR-SVR optimization model for monthly precipitation prediction [J]. Journal of Hydraulic Engineering, 2019, 50 (12): 1529-1537. (in Chinese)
- [7] Xu Tianfang, Liang Feng. Machine learning for hydrologic sciences: An introductory overview [J]. Wiley Interdisciplinary Reviews: Water, 2021, 8(5). DOI:10.1002/wat2.1533
- [8] Zhao Youyi, Luo Shangxue, Cai Jiafang, et al. Monthly precipitation prediction based on the CEEMDAN-BMA model [J]. Water Resources Management, 2024, 38(14): 5661-5681.
- [9] 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 (2): 13-18.
Xu Dongmei, Wang Yaqin, Wang Wenchuan. Monthly precipitation prediction model based on VMD-TCN [J]. Journal of China Hydrology, 2022, 42 (2): 13-18. (in Chinese)
- [10] PARVIZ L, GHORBANPOUR M. A hybrid EMD and MODWT models for monthly precipitation forecasting using an innovative error decomposition method [J]. Stochastic Environmental Research and Risk Assessment, 2024, 38(10): 4107-4130.
- [11] Song Chao, Chen Xiaohong, Wu Pan, et al. Combining time varying filtering based empirical mode decomposition and machine learning to predict precipitation from nonlinear series [J]. Journal of Hydrology, 2021, 603. DOI:10.1016/j.jhydrol.2021.126914.
- [12] 陈云飞, 刘祖钰, 刘秀花, 等. EMD及其扩展方法在水文学中的研究进展及应用综述 [J]. 灌溉排水学报, 2025, 44 (2): 101-112.
Chen Yunfei, Liu Zuyu, Liu Xiuhua, et al. Advances and applications of empirical mode decomposition and its variants in hydrology: A review [J]. Journal of Irrigation and Drainage, 2025, 44 (2): 101-112. (in Chinese)
- [13] Wang Wenchuan, Cheng Qi, Chau Kwokwing, et al. An enhanced monthly runoff time series prediction using extreme learning machine optimized by salp swarm algorithm based on time varying filtering based empirical mode decomposition [J]. Journal of Hydrology, 2023, 620. DOI:10.1016/j.jhydrol.2023.129460
- [14] 王秀杰, 乔鸿飞, 曾勇红, 等. 基于TVF-EMD、GRA和LightGBM的日径流预测组合模型 [J]. 水资源保护, 2023, 39 (5): 135-142, 151.
Wang Xiujie, Qiao Hongfei, Zeng Yonghong, et al. TVF-EMD, GRA, and LightGBM combined daily runoff prediction model [J]. Water Resources Protection, 2023, 39 (5): 135-142, 151. (in Chinese)
- [15] KARBASI M, JAMEI M, ALI M, et al. Development of an enhanced bidirectional recurrent neural network combined with time-varying filter-based empirical mode decomposition to forecast weekly reference evapotranspiration [J]. Agricultural Water Management, 2023, 290. DOI:10.1016/j.agwat.2023.108604.
- [16] Song Chao, Chen Xiaohong, Wu Pan, et al. Combining time varying filtering based empirical mode decomposition and machine learning to predict precipitation from nonlinear series [J]. Journal of Hydrology, 2021, 603. DOI:10.1016/j.jhydrol.2021.126914.
- [17] ADARYANI F R, MOUSAVI S J, JAFARI F. Short-term rainfall forecasting using machine learning-based approaches of PSO-SVR, LSTM and CNN [J]. Journal of Hydrology, 2022, 614. DOI:10.1016/j.jhydrol.2022.128463
- [18] MALIK A, KUMAR A, SINGH R P. Application of heuristic approaches for prediction of hydrological drought using multi-scalar streamflow drought index [J]. Water Resources Management, 2019, 33(11): 3985-4006.

- [19] PARSAIE A, GHASEMLOUNIA R, GHAREHBAGHI A, et al. Novel hybrid intelligence predictive model based on successive variational mode decomposition algorithm for monthly runoff series [J]. *Journal of Hydrology*, 2024, 634. <https://doi.org/10.1016/j.jhydrol.2024.131041>.
- [20] 朱煜宵, 张代青. 基于XGBoost修正的融合神经网络在降水量预测中的应用[J/OL]. *人民珠江*, 2026, 1-18.
Zhu Y X, Zhang D Q. Application of fusion neural network based on XGBoost correction in precipitation prediction [J/OL]. *Pearl River*, 2026, 1-18. (in Chinese)
- [21] MONEGO V S, ANOCHI J A, VELHO H F D. A machine learning algorithm for uncertainty quantification in climate precipitation prediction over South America [J]. *Computational & Applied Mathematics*, 2025, 45 (2). DOI: 10.1016/j.jhydrol.2024.131041.
- [22] 赵子惜. 1980-2021年广州市降水量年内分配不均匀性及变化规律[J]. *人民珠江*, 2025, 46 (10): 1-9.
Zhao Zixi. Uneven distribution and variation patterns of annual precipitation in Guangzhou from 1980 to 2021 [J]. *Pearl River*, 2025, 46 (10): 1-9. (in Chinese)
- [23] 桑燕芳, 谢平, 顾海挺, 等. 水文过程非平稳性研究若干问题探讨[J]. *科学通报*, 2017, 62 (4): 254-261.
Sang Yanfang, Xie Ping, Gu Haiting, et al. Discussion on several major issues in the studies of hydrological nonstationarity [J]. *Chinese Science Bulletin*, 2017, 62 (4): 254-261. (in Chinese)

A Hybrid Monthly Precipitation Prediction Model Based on TVF-EMD and SVR

LAI Qifeng, ZENG Jiuhan

(Ganzhou Water Conservancy and Electric Power Survey Design and Research Institute Co., Ltd., Ganzhou Jiangxi, 341000)

Abstract: Accurate monthly precipitation forecasting is crucial for the scientific management and optimal allocation of water resources, with significant implications for reservoir operation and agricultural irrigation. However, under the combined influence of climate change and human activities, monthly precipitation series often exhibit complex nonlinear and non-stationary characteristics. Traditional linear statistical models and single machine learning approaches frequently fail to capture their dynamic evolution patterns, leading to limited prediction accuracy. To address this challenge, this study proposes a hybrid forecasting model that integrates Time-Varying Filtering-based Empirical Mode Decomposition (TVF-EMD) with Support Vector Regression (SVR). TVF-EMD, an adaptive signal decomposition technique, effectively mitigates the mode-mixing problem inherent in conventional Empirical Mode Decomposition (EMD) by decomposing the non-stationary precipitation series into relatively stable subcomponents. Independent SVR models are then developed to predict each subcomponent, and the final monthly precipitation forecast is obtained by aggregating these predictions. Using monthly precipitation data from 1951 to 2020 collected at the Ganxian Meteorological Station in Ganzhou City, Jiangxi Province, China, we evaluate and compare the predictive performance of four models: Multiple Linear Regression (MLR), SVR, EMD-SVR, and the proposed TVF-EMD-SVR. The results demonstrate that SVR significantly outperforms MLR in characterizing the nonlinear features of monthly precipitation. By introducing the "decomposition-prediction-reconstruction" framework, the EMD-SVR model achieves a 92.50% improvement in the Nash-Sutcliffe Efficiency (NSE) coefficient compared to the standalone SVR model. Furthermore, by employing TVF-EMD for decomposition, the TVF-EMD-SVR hybrid model yields a further substantial reduction in prediction error. Specifically, compared to the EMD-SVR model, TVF-EMD-SVR reduces the Mean Absolute Error and Root Mean Square Error by 67.83% and 67.67%, respectively, attaining an NSE value of 0.93. These findings confirm that SVR exhibits strong adaptability for nonlinear monthly precipitation prediction, while TVF-EMD more effectively alleviates the adverse impacts of non-stationarity. The integration of these two methods significantly enhances prediction accuracy. The proposed TVF-EMD-SVR hybrid model provides a reliable methodological framework for monthly precipitation forecasting under complex climatic conditions and can deliver more accurate forecasts to support decision-making in regional reservoir operation and agricultural production.

Keywords: Monthly precipitation series; TVF-EMD; SVR; Hybrid prediction model; Ganzhou, Jiangxi Province

(责任编辑:程 茜)