

DOI: 10.13476/j.cnki.nsbdkj.2020.0116

徐冬梅,张一多,王文川. 基于小波包分解的LS-SVM-ARIMA组合降水预测[J]. 南水北调与水利科技(中英文), 2020, 18(6): 71-77. XU D M, ZHANG Y D, WANG W C. Precipitation prediction using LS-SVM and ARIMA combined model based on wavelet packet decomposition[J]. South-to-North Water Transfers and Water Science & Technology, 2020, 18(6): 71-77. (in Chinese)

基于小波包分解的LS-SVM-ARIMA组合降水预测

徐冬梅,张一多,王文川

(华北水利水电大学 水资源学院, 郑州 450046)

摘要:针对降水量影响因素众多,是一种复杂的非平稳、非线性且存在噪声问题的时间序列的特点,提出一种基于小波包分解的LS-SVM与ARIMA组合模型的年降水量预测方法。利用小波包将降水序列分解成低频趋势序列和高频细节序列;应用LS-SVM模型预测低频趋势序列,ARIMA模型预测高频细节序列;将两个模型的预测结果叠加,得到年降水量的预测值。实例验证表明:小波包对时间序列的分解比小波分解更精细,组合模型预测能够全面的提取降水序列中所包含的信息,更好地反映年降水量随时间变化规律,提高了年降水量预测的精准度,为降水量预测提供一种新方法。

关键词:降水预测;小波包分解;LS-SVM模型;ARIMA模型;金沙县

中图分类号:TV125 文献标志码:A 开放科学(资源服务)标志码(OSID):



Precipitation prediction using LS-SVM and ARIMA combined model based on wavelet packet decomposition

XU Dongmei, ZHANG Yiduo, WANG Wenchuan

(School of Water Resources, North China University of Water Resources and Electric Power, Zhengzhou 450046, China)

Abstract: An annual precipitation prediction method is proposed based on wavelet packet decomposition of LS-SVM and ARIMA combined model because the precipitation has a complex non-stationary, nonlinear, and noisy time series. The wavelet packet is used to decompose the precipitation sequence into a low-frequency trend sequence and high-frequency detail sequence. The LS-SVM model is used to predict the low-frequency trend sequence, and the ARIMA model is used to predict the high-frequency detail sequence. The prediction results of the two models are superimposed to get the predicted value of annual precipitation. The case study shows that: the decomposition of time series by wavelet packet is more precise than the wavelet decomposition, the combined model prediction can comprehensively extract the information contained in the precipitation sequence, better reflect the change of precipitation with time, and improve the annual precipitation forecast which provides a new method for the prediction of precipitation.

Key words: precipitation forecast; wavelet packet transform; LS-SVM model; ARIMA model; Jinsha county

收稿日期:2019-12-31 修回日期:2020-04-03 网络出版时间:2020-04-28

网络出版地址: <http://kns.cnki.net/kcms/detail/13.1430.TV.20200428.1028.010.html>

基金项目:河南省高校科技创新团队(18IRTSTHN009);河南省重点研发与推广专项(202102310259);国家自然科学基金(51509088; 51709108)

作者简介:徐冬梅(1977—),女,吉林双辽人,副教授,博士,主要从事水资源系统分析研究。E-mail: xudongmei@ncwu.edu.cn

通信作者:王文川(1976—),男,河南鹿邑人,教授,博士生导师,主要从事水文学水资源系统分析、优化建模等研究。E-mail: wangwen1621@163.com

降水是地区水资源的重要补给方式,对地区生活、生产有重要影响。降水量异常是很多洪涝灾害的直接原因,准确预测降水量具有重要意义。降水量预测的相关研究受到国内外众多学者重视。近年来,众多学者在降水量预测研究中采用回归分析法^[1-2]、时间序列预测法^[3-4]、人工神经网络^[5]、随机森林模型^[6]、最小支持二乘向量机^[7]等方法均取得了较好的效果,但缺少对降水序列的时序特征分析,不能充分挖掘、提取降水序列所包含的信息。事实上降水形成的物理过程极其复杂,具有周期性、复杂性、非线性等特点,降水量波动受多种变化趋势交叉影响,需要对其进行细致分析,才能使降水预测精度更高。

一些学者将小波分析与不同预测方法耦合进行降水量预测:徐淑琴等^[8]将小波分析与时间序列组合对虎林市 853 农场进行年降水量预测;李红亚等^[9]提出了一种基于小波分析和多细胞基因表达式编程的降水预测算法;陈沪生等^[10]将小波分析与 ARIMA 模型组合并对黄山市年降水量进行预测;Pandey 等^[11]用小波与回归分析法分析印度的降水长期变化趋势。小波能够有效提取序列不同频段的信息,在一定程度上解决传统预测方法缺乏对降水序列时序特征分析的问题。而降水序列复杂多变,包含大量细节信息,小波分解对数据高频细节部分分解程度低,细节信息提取不够充分。本文采用能全面提取数据信息的小波包将年降水量分解为 4 个低频趋势序列、4 个高频细节序列,并针对低频趋势序列、高频细节序列的特点,选用 ARIMA 模型对高频细节序列建模、LS-SVM 模型对低频趋势序列建模。ARIMA 结构简单、可解释性强,在降水预测中已有广泛应用,选择 ARIMA 模型预测具有线性特征的高频细节序列能够以较低的运算复杂度获得理想的预测结果。但 ARIMA 模型只能预测线性、确定的变化过程,而低频趋势序列代表降水序列的长期趋势具有非线性特点,LS-SVM 模型可以以任意精度逼近非线性函数,能够较好地拟合降水序列的非线性变化趋势而且避免了 SVM 模型的复杂计算量,因此选择 LS-SVM 模型预测低频趋势序列。

1 研究方法

1.1 小波包分解

小波包分解(wavelet packet decomposition, WPD)是在小波基础上发展的一种更精细的信号分解方法,本质上是在对小波分解所得到的信号

进行进一步分解,对信号的高频部分的分辨率要好于小波分解^[12](wavelet transform),而且这种分解既无冗余,也无疏漏。理论上信号被小波包分解为 3 层就能够提取信号中有效信息,逼近任意非线性函数,从而解决实际问题^[13]。

对于本文要进行的降水预测研究,信号 $Y(0,0)$ 即为历史降水数据,经小波包 3 层分解映射到各子空间中,从左至右频率由低到高,见图 1。

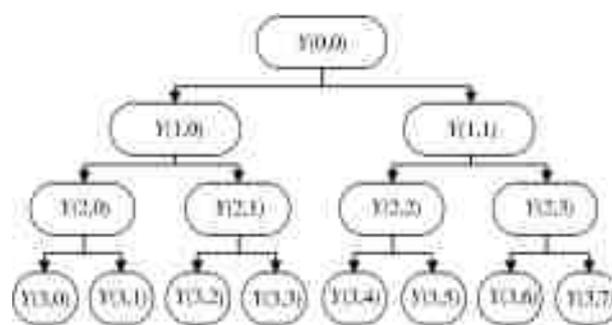


图 1 小波包分解层次结构

Fig. 1 Wavelet packet decomposition hierarchy diagram

1.2 LS-SVM 模型

最小二乘支持向量机(Least Squares Support Vector Machine, LS-SVM)是标准支持向量机(SVM)的简化与改进模型,规避了复杂的二次规划求解,计算复杂度更小,收敛速度更快^[14]。原理^[15]为

假设有 n 组数据点,样本集 $S = \{(x_1, y_1), \dots, (x_l, y_l), x_i \in R^n, y_i \in R\} i = 1, 2, 3, \dots, l$ 。其中: l 为样本数量; x_i 为输入向量; y_i 为相应的输出值。接着构造样本集的线性回归函数

$$f(x) = w^T \Phi(x) + b \quad (1)$$

式中: w 为权值向量; $w_i \in R^n$; 偏置常量 $b \in R$; $\Phi(\cdot)$ 为解决非线性问题的核函数。

基于结构风险最小化的原则,定义优化问题为

$$\min J_{LS}(w, \xi) = \frac{1}{2} \|w\|^2 + \frac{1}{2} \gamma \sum_{i=1}^l \xi_i^2 \quad (2)$$

式中: $\|w\|^2$ 代表模型复杂度; γ 为正规化参数; ξ_i 为误差项的第 i 个分量。

根据 Karush-Kuhn-Tucker 条件和 Mercer 条件将 LS-SVM 的优化问题转化为求解线性方程,得到 x 时刻的 LS-SVM 预测模型的非线性回归方程

$$f(x) = \sum_{i=1}^l \alpha_i K(x, x_i) + b \quad (3)$$

式中: $\alpha_i (i = 1, 2, \dots, l)$ 为拉格朗日乘子; x 为支持向量; x_i 为第 i 个支持向量的输入; $f(x)$ 为预测输出值; $K(x, x_i)$ 为把样本映射到特征向量的核函数,核函数采用径向基 RBF 公式为

$$K(x_i, x_j) = e^{-\frac{\|x_i - x_j\|^2}{2\sigma}} \quad (4)$$

式中: σ 为径向基函数核的超参数。

1.3 PSO 算法

LS-SVM 预测精度主要受径向基函数核的超参数 σ 以及正规化参数 γ 的取值影响。采用粒子群优化算法 (particle swarm optimization, PSO) 对其进行优选^[16]。

算法原理: 首先初始化一群随机粒子, 即优化问题随机解, 用位置、速度和适应度值等 3 项指标表示该粒子特征。粒子根据式(5)和式(6)来更新自己的速度和位置, 将其代入优化目标函数计算出相应的适应值来衡量 X_i^k 的优劣。在每一次迭代中, 粒子通过个体极值 P_{best} 和群体极值 G_{best} 来更新自己

$$V_i^{k+1} = wV_i^k + c_1 \text{rand}() (P_{best_i}^k - X_i^k) + c_2 \text{rand}() (G_{best_i}^k - X_i^k) \quad (5)$$

$$X_i^{k+1} = X_i^k + V_i^{k+1} \quad (6)$$

式中: $i=0, 1, \dots, N$, N 为粒子总个数; $k=0, 1, \dots, M$, M 为最大迭代次数; V_i^k 为第 i 个粒子 k 次迭代时的速度; X_i^k 为第 i 个粒子 k 次迭代时的位置; w 为惯性因子; $\text{rand}()$ 为 $(0, 1)$ 之间的随机数; c_1 和 c_2 为学习因子。

1.4 ARIMA 模型

差分整合移动平均自回归模型简称 ARIMA 模型, 该模型可靠性高, 模型简单, 只需要考虑内生变量, 但模型要求输入的时间序列数据必须是稳定的^[17], 基本思想是: 将预测对象随时间推移而形成

的数据序列视为一个随机序列, 并假定序列是平稳且线性变化, 用一定的数学模型来近似描述这个序列, 从时间序列的过去值及现在值来预测未来值。通用数学表达式^[18]为

$$\hat{y}_t = \varphi_1 y_{t-1} + \varphi_2 y_{t-2} + \dots + \varphi_p y_{t-p} + \varepsilon_t - (\theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}) \quad (7)$$

式中: \hat{y}_t 为 t 时刻时间序列; $\varphi_1, \varphi_2, \dots, \varphi_p$ 为自回归系数; $\theta_1, \theta_2, \dots, \theta_p$ 为滑动平均阶数; ε_t 为 t 时刻残差序列; p 为自回归阶数; q 为滑动平均阶数。

2 实例应用

金沙县位于贵州省西北部, 地质环境脆弱^[19-20]。丰水年汛期 (5—9 月) 常出现暴雨、大暴雨, 导致山洪爆发并诱发泥石流、滑坡等山洪地质灾害。枯水年常出现干旱现象且多发生在春季、夏季上旬, 直接影响人民饮水安全和农作物产量^[21]。因此, 对金沙县年降水量进行预测对该区域防洪、抗旱、农业生产等工作开展具有现实指导意义。

2.1 小波包分解降水时序数据

1958—2018 年金沙县的年降水量数据见图 2, 可以看出年降水量数据为非平稳序列, 波动较大。利用 db4 小波将 1958—2018 年的年降水量数据进行 3 层小波包分解, 得到 8 个分解空间的年降水量数据, 其中 $[3, 0]$ 、 $[3, 1]$ 、 $[3, 2]$ 、 $[3, 3]$ 等 4 个低频空间的数据及波形见图 3, $[3, 4]$ 、 $[3, 5]$ 、 $[3, 6]$ 、 $[3, 7]$ 等 4 个高频空间的数据及波形见图 4。

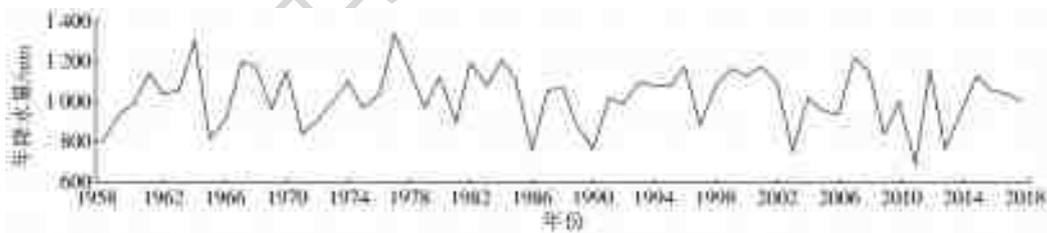


图 2 1958—2018 年降水量序列

Fig. 2 Precipitation sequence from 1958 to 2018

2.2 低频趋势序列建模

在 MATLAB2018a 软件中导入分解后的 $[3, 0]$ 、 $[3, 1]$ 、 $[3, 2]$ 、 $[3, 3]$ 等 4 个低频空间的数据, 用 PSO 算法进行参数的全局寻优计算, 确定参数最优解后利用 LS-SVM 模型建模, 其步骤如下。

Step 1: 确定模型输入值。利用模型的阶数来确定前多少年的降水量对当年降水量有影响, 以预测结果均方差最小作为是否继续扩阶的标准。即假设 LS-SVM(n) 为拓阶 n 次后的模型, LS-SVM($n+1$) 为拓阶 ($n+1$) 次后的模型, 根据两模型 RMSE 指

标进行判定, 若 $\text{RMSE}(n) > \text{RMSE}(n+1)$, 则继续拓阶, 反之, 若 $\text{RMSE}(n) < \text{RMSE}(n+1)$, 则停止拓阶, 并取 LS-SVM(n) 为最终模型。通过计算, 模型的最优阶数为 4, 说明降水序列中当前数据与前 4 年数据密切相关, 因此把前 4 年的数据作为 LS-SVM 的输入值来预测当前值^[22]。

Step 2: 选定优化参数确定寻优区间。利用 PSO 算法对模型径向基函数核的超参数 σ 、正规化参数 γ 进行参数寻优, 将两参数的搜索范围均设定为 $10^{-4} \sim 10^4$ 。

Step 3: 确立目标函数并优化参数。本文采用真实值与预测值的均方根误差(RMSE)作为目标函数,均方根误差公式为

$$f(y) = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (8)$$

式中: y_i 为预测样本的真实值; \hat{y}_i 为预测样本的预测值; $i=1,2,3,4,5$ 。

确立目标函数后,对两参数进行寻优计算,经过不断优化,当适应度值不再变化时得到结果为径向基函数核的超参数 σ 、正规化参数 γ 的最优参数组合。经计算得到的最优参数见表 1。

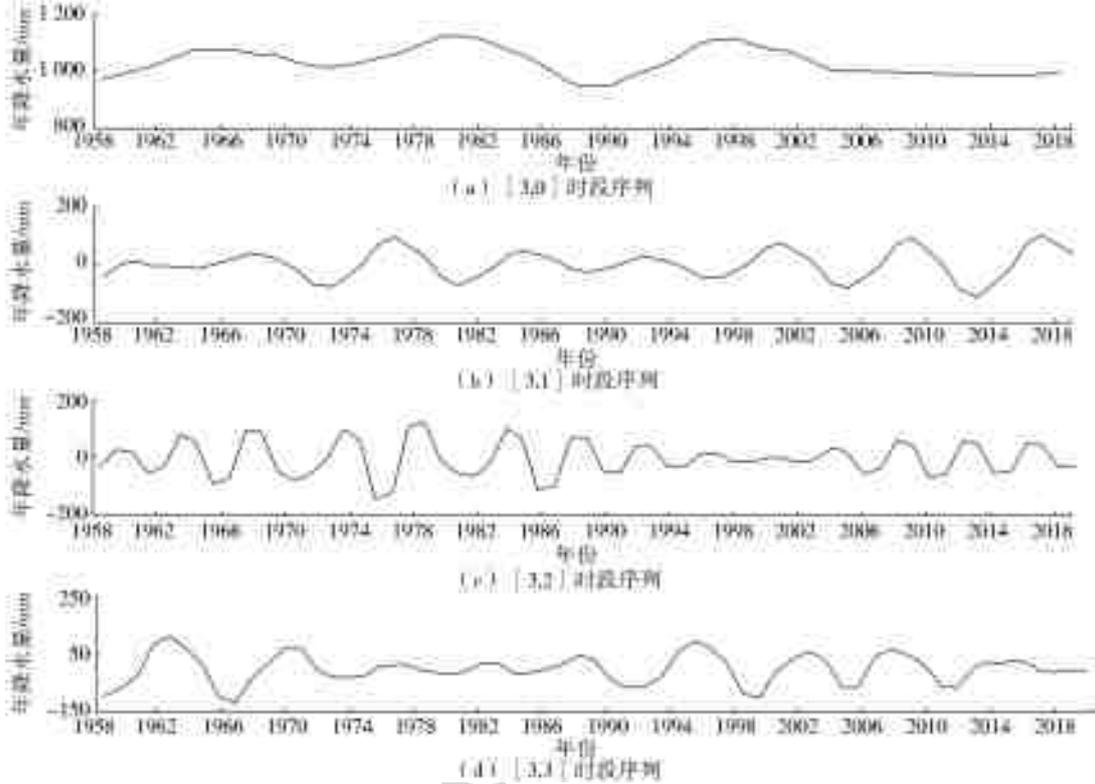


图 3 年降水序列低频趋势序列分解

Fig. 3 Decomposition of low-frequency trend sequence of annual precipitation series

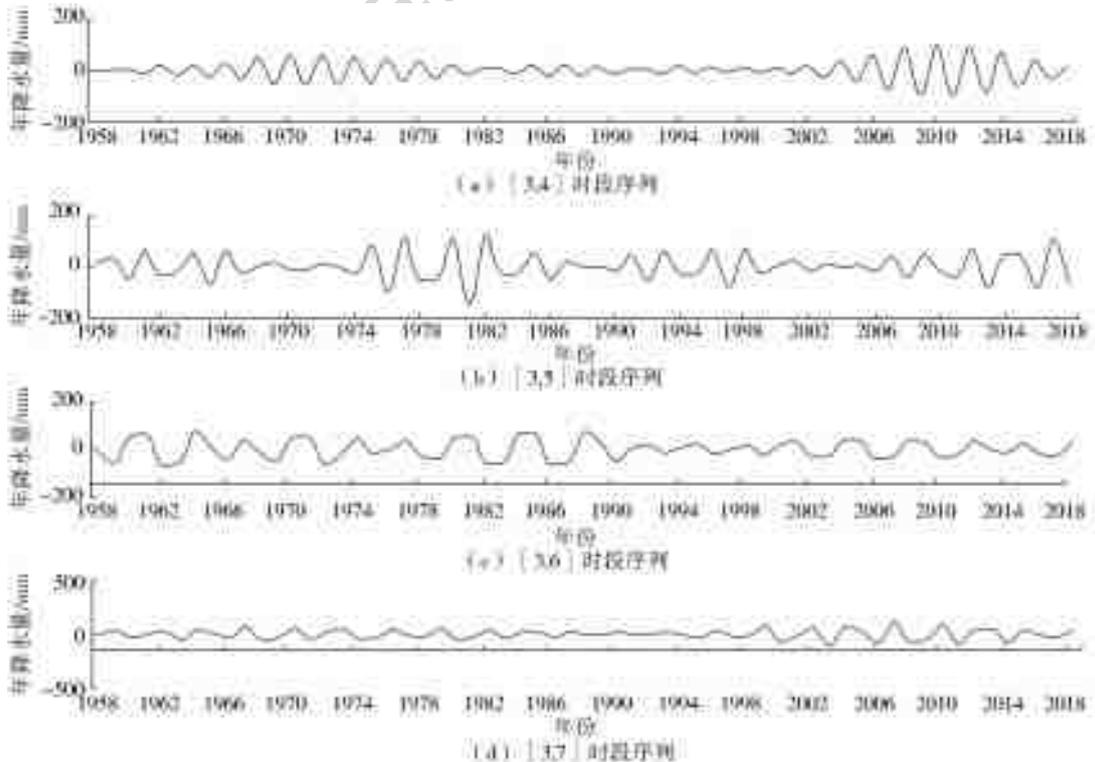


图 4 年降水序列高频细节序列分解

Fig. 4 Decomposition of high-frequency detail sequence of annual precipitation sequence

Step 4:建立 LS-SVM 预测模型。以[3,0]、[3,1]、[3,2]、[3,3]时段序列 1958—2013 年的数据作为训练样本。导入计算得到的各序列参数最优组合,建立预测模型,得出各时段的 2014—2018 年预测值。

表 1 低频趋势序列参数寻优结果
Tab. 1 Optimization results of low-frequency trend sequence parameters

分解序列	超参数 σ	正规化参数 γ
[3,0]	5 385.0	106.431 0
[3,1]	6 982.8	1 366.500 0
[3,2]	8 194.7	0.000 1
[3,3]	8 181.9	6 838.000 0

2.3 高频细节序列建模

利用 EViews10.0、SPSS25 软件,导入分解后的[3,4]、[3,5]、[3,6]、[3,7]这 4 个高频空间的数据,建立 ARIMA 模型,其步骤(图 5)^[23]如下。



图 5 ARIMA 模型建模步骤
Fig. 5 ARIMA model modeling steps

Step 1:序列平稳化。将数据导入 EViews10.0 软件,选择 ADF 单位根检验法对各时段序列进行单位根检验,验证序列是否平稳。

Step 2:确定 p 、 q 值,建立模型。利用 SPSS25 软件得到各序列自相关(AF)和偏相关系数(PAF)图。观察 p 、 q 取值确定建立 AR、MA、ARMA(p , d , q)模型哪一种通过施瓦茨准则(SBIC)最小和平稳 R^2 最大,选取初步合适的模型,进行下一步残差检验。

Step 3:模型检验。利用 SPSS25 软件检验模型残差显著性,若模型的残差序列不存在自相关,为白

噪声序列,表明模型是合理的,若存在自相关返回第二步再次选取模型。

Step 4:模型预测。根据建立的模型,对各序列进行拟合,得各序列的预测值。

[3,5]时段序列差分后仍不稳定,不适用于 ARIMA 模型。使用 LS-SVM 模型对[3,5]时段序列建模,步骤同低频趋势序列建模流程。PSO 优化后的超参数 σ 、正规化参数 γ 分别为 4 481 和 28.65。

依上述步骤对[3,4]、[3,6]、[3,7]各时段序列建立的 ARIMA 模型(p, d, q)各参数值见表 2。

表 2 [3,4]、[3,6]、[3,7]ARIMA 模型参数
Tab. 2 ARIMA model parameters for[3,4],[3,6],[3,7]

分解序列	ARIMA 模型参数
[3,4]	ARIMA(2,0,0)
[3,6]	ARIMA(5,0,3)
[3,7]	ARIMA(7,0,2)

2.4 组合模型建立

分别对分解后各时段序列建立模型(图 6),得出各序列预测值,见表 3。金沙县降水序列的最终预测值是各分解序列预测值的线性叠加,见式(9)。

$$\hat{y} = \hat{y}_{[3,0]} + \hat{y}_{[3,1]} + \hat{y}_{[3,2]} + \hat{y}_{[3,3]} + \hat{y}_{[3,4]} + \hat{y}_{[3,5]} + \hat{y}_{[3,6]} + \hat{y}_{[3,7]} \quad (9)$$

式中: \hat{y} 为组合模型降水序列预测值; $\hat{y}_{[3,i]}$ 为[3, i]时段序列数据。

相对误差

$$\delta = \frac{|y_i - \hat{y}_i|}{\hat{y}_i} \times 100\% \quad (10)$$

式中: y_i 为预测结果对应年份的真实值; \hat{y}_i 为预测值; $i=1,2,3,4,5$ 。

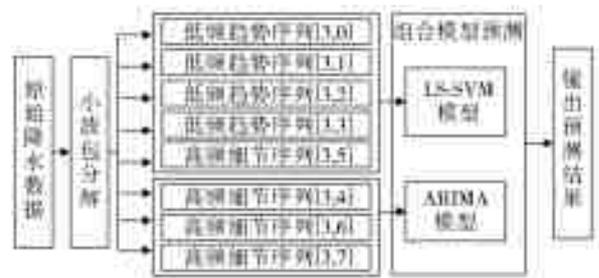


图 6 组合模型建模步骤
Fig. 6 Composite model modeling steps

表 3 组合模型年降水量预测结果
Tab. 3 Combined model prediction results

年份	真实值/mm	[3,0]	[3,1]	[3,2]	[3,3]	[3,4]	[3,5]	[3,6]	[3,7]	预测值/mm	相对误差/%
2014	972.9	982.69	-9.65	-45.13	19.01	74.47	43.78	-14.26	-68.87	982.05	0.94
2015	1 136.1	986.46	64.88	46.55	-3.38	-65.47	38.35	21.07	37.12	1 125.57	0.93
2016	1 061.7	988.30	102.96	42.87	-10.06	55.17	-79.40	-13.60	-17.35	1 068.89	0.68
2017	1 046.2	988.95	75.56	-30.84	-9.99	-43.97	103.46	-28.33	-28.37	1 026.47	1.89
2018	1 003.6	996.82	32.62	-35.25	2.27	32.17	-69.22	32.10	29.84	1 021.36	1.77

为了验证基于小波包分解的 LS-SVM-ARIMA 组合模型对降水序列预测的优势,将该组合模型与基于小波分解的 ARIMA 模型以及基于小波分解的 ARIMA-LS-SVM 模型的预测结果进行对比。

对比模型采用 db4 小波对原始数据进行 4 层

小波分解^[24],通过 MATLAB2018a 软件的小波工具箱分解为趋势序列 a 和细节序列 d₁、d₂、d₃、d₄,对细节序列建立 ARIMA 模型,将趋势序列 a 分别用 ARIMA 模型和 LS-SVM 模型建模。详细结果见表 4、5。

表 4 小波分析-ARIMA 模型年降水量预测结果
Tab. 4 Wavelet analysis-ARIMA model prediction results

年份	真实值/mm	d ₁	d ₂	d ₃	d ₄	a(ARIMA)	预测值/mm	相对误差/%
2014	972.9	49.82	-17.02	-10.87	-7.67	997.26	1 011.52	3.97
2015	1 136.1	-14.53	35.35	77.89	-2.76	999.23	1 095.18	3.60
2016	1 061.7	-13.54	3.32	112.06	1.66	1 002.10	1 105.61	4.14
2017	1 046.2	-9.63	-30.82	74.26	5.28	1 005.78	1 044.87	0.13
2018	1 003.6	37.13	2.07	20.61	7.80	1 010.14	1 077.75	7.39

表 5 小波-ARIMA-LS-SVM 模型年降水量预测结果
Tab. 5 Prediction results of wavelet-ARIMA-LS-SVM model

年份	真实值/mm	d ₁	d ₂	d ₃	d ₄	a(LS-SVM)	预测值/mm	相对误差/%
2014	972.9	49.82	-17.02	-10.87	-7.67	993.82	1 008.08	3.62
2015	1 136.1	-14.53	35.35	77.89	-2.76	992.14	1 088.08	4.23
2016	1 061.7	-13.54	3.32	112.06	1.66	990.61	1 094.11	3.05
2017	1 046.2	-9.63	-30.82	74.26	5.28	989.43	1 028.53	1.69
2018	1 003.6	37.13	2.07	20.61	7.80	988.69	1 056.30	5.25

引入均方根误差、平均绝对误差和平均绝对百分比误差作为评价指标,衡量各模型年降水量预测的优劣。均方根误差(RMSE)公式见式(8),平均绝对误差(MAE)、平均绝对百分比误差(MAPE)公式^[25]为

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (11)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (12)$$

式中: y_i 为预测结果对应年份的真实值; \hat{y}_i 为预测值; i=1,2,3,4,5。

表 6 不同模型预测结果对比

Tab. 6 Comparison of prediction results of different models

评价指标	小波-ARIMA 模型	小波-LS-SVM-ARIMA 模型	小波包-LS-SVM-ARIMA 模型
MAE	53.56	37.20	12.87
RMSE	70.08	39.20	13.79
MAPE/%	4.94	3.57	1.24

表 6 计算出 3 种模型的平均均绝对误差(MAE)、均方根误差(RMSE)和平均绝对百分比误差(MAPE),可以看出:小波包分解的 LS-SVM-ARIMA 模型的 3 项评价指标均为最小,预测精度最高;小波-LS-SVM-ARIMA 模型的精度次之;小

波-ARIMA 模型的精度最低。其原因在于降水序列中包含非线性特征和线性特征,而 ARIMA 模型用于预测时假定序列是线性变化的,有局限性,难以预测序列的非线性变化,用 ARIMA 模型预测高频细节序列、LS-SVM 模型预测低频趋势序列可以充分提取降水序列的线性变化和非线性变化的特点,有效提高预测精度;同时小波包分解相比小波分解能够更全面的分解降水数据,提取降水数据中包含的细节信息,在完整保留降水序列信息的同时,降低了序列的随机性导致的误差,使得年降水量的预测精度更高,结果更为可靠。

3 结论与建议

(1)针对降水序列波动呈现多种变化趋势,使用小波分析不能有效提取降水数据中的全部信息,尤其是细节信息;单一模型进行降水预测也不能考虑其变动的全部趋势,往往只是侧重线性变化和非线性变化中的一种。提出了通过小波包分解降水序列得到 8 个不同频段的变化趋势,应用 LS-SVM 模型拟合降水量的高频细节序列,ARIMA 模型拟合降水量的低频趋势序列,得到组合预测的结果。

(2)提出的小波包-LS-SVM-ARIMA 组合模型与小波-ARIMA 模型相比,平均绝对误差(MAE)、

均方根误差 (RMSE) 和平均绝对百分比误差 (MAPE) 分别减少了 75.97%、80.32% 和 74.88%。

(3) 提出的小波包-LS-SVM-ARIMA 组合模型与小波-LS-SVM-ARIMA 模型相比, 平均绝对误差 (MAE)、均方根误差 (RMSE) 和平均绝对百分比误差 (MAPE) 分别减少了 65.39%、64.82% 和 65.24%。

(4) 提出的模型有效地提高了年降水量的预测精度, 但在研究中未考虑其他因素对降水的影响。未来降水预测方法应进一步引入影响降水量的相关因素作为自变量, 建立多因素与数理统计方法耦合的预测模型。

参考文献:

- [1] 宋楠. 多元自回归模型在区域中长期水文预报中应用研究[J]. 水土保持应用技术, 2017(2): 22-25. DOI: 10.3969/j.issn.1673-5366.2017.02.09.
- [2] FAN L, LU C H, YANG B, et al. Long-term trends of precipitation in the north China Plain[J]. Journal of Geographical Sciences, 2012, 22(6): 989-1001. DOI: 10.1007/s11442-012-0978-2.
- [3] 刘贤赵, 邵金花. 烟台地区降水量的 ARIMA 随机模型研究[J]. 数学的实践与认识, 2006, 36(8): 8-12. DOI: 10.3969/j.issn.1000-0984.2006.08.002.
- [4] 吕树龙. ARIMA 模型在降水量预测中的应用[J]. 水科学与工程技术, 2012(2): 6-8. DOI: 10.3969/j.issn.1672-9900.2012.02.003.
- [5] 李永华, 刘德, 金龙. 基于 BP 神经网络的汛期降水预测模型研究[J]. 气象科学, 2002(4): 461-467. DOI: 10.3969/j.issn.1009-0827.2002.04.011.
- [6] 黄玺玮, 王利, 杨双宁, 等. 基于随机森林的内江市降水量中长期预测[J]. 阴山学刊(自然科学版), 2017, 31(4): 107-110. DOI: 10.13388/j.cnki.ysajs.20170628.022.
- [7] 孟锦根. 基于 PSO_LSSVM 的干旱区中长期降水预测模型研究[J]. 长江科学院院报, 2016, 33(10): 40-44. (in Chinese) DOI: 2016, 33(10): 40-44.
- [8] 徐淑琴, 雷兴元, 刘宇佳, 等. 基于时间序列与小波分析耦合模型区域降雨量预测研究[J]. 东北农业大学学报, 2015, 46(11): 63-69. DOI: 10.19720/j.issn.1005-9369.2015.11.010.
- [9] 李红亚, 彭昱忠, 邓楚燕, 等. 多细胞基因表达式编程和小波分析的降水预测[J]. 计算机仿真, 2019, 36(8): 388-393. DOI: 10.3969/j.issn.1006-9348.2019.08.081.
- [10] 陈沪生, 周玉良, 周平, 等. 基于小波和 ARIMA 的广州市年降水量分析及预测[J]. 南水北调与水利科技, 2019, 17(5): 50-55. DOI: 10.13476/j.cnki.nsbdkq.2019.0109.
- [11] PANDEY B K, TIWARI H, KHARE D. Trend analysis using discrete wavelet transform (DWT) for long-term precipitation (1851-2006) over India[J]. Hydrological Sciences Journal, 2017, 62(13): 2187-2208. DOI: 10.1080/02626667.2017.1371849.
- [12] 叶瑞丽, 郭志忠, 刘瑞叶, 等. 基于小波包分解和改进 Elman 神经网络的风电场风速和风电功率预测[J]. 电工技术学报, 2017, 32(21): 103-111. DOI: 10.19595/j.cnki.1000-6753.tces.160727.
- [13] 杨茂, 杨宇. 基于小波包与 LSSVM 的短期光伏输出功率预测研究[J]. 可再生能源, 2019, 37(11): 1595-1602. DOI: 10.3969/j.issn.1671-5292.2019.11.003.
- [14] 梅倩. LS-SVM 在时间序列预测中的理论与应用研究[D]. 重庆: 重庆大学, 2013. DOI: 10.7666/d.D354950.
- [15] SUYKENS J A K, GESTEL T V, BRABANTER J D, et al. Least squares support vector machines[M]. World Scientific, 2002. DOI: 10.1142/5089.
- [16] 姚全珠, 蔡婕. 基于 PSO 的 LS-SVM 特征选择与参数优化算法[J]. 计算机工程与应用, 2010, 46(1): 134-136, 229. DOI: 10.3778/j.issn.1002-8331.2010.01.041.
- [17] PAI P F, LIN C S. A hybrid ARIMA and support vector machines model in stock price forecasting[J]. Omega, 2005, 33(6): 497-505. DOI: 10.1016/j.omega.2004.07.024.
- [18] 张杰, 刘小明, 贺玉龙, 等. ARIMA 模型在交通事故预测中的应用[J]. 北京工业大学学报, 2007, 33(12): 1295-1299. DOI: 10.3969/j.issn.0254-0037.2007.12.012.
- [19] 陈智虎, 杨广斌, 杨春艳, 等. 典型喀斯特地貌类型区小流域划分: 以贵州省金沙县为例[J]. 中国岩溶, 2016, 35(3): 262-268. DOI: 10.11932/karst20160303.
- [20] 姚浪, 吴姗, 王丽媛, 等. 金沙县两次大暴雨过程对比分析[J]. 贵州气象, 2016, 40(6): 54-58. DOI: 10.3969/j.issn.1003-6598.2016.06.010.
- [21] 赵廷爵, 温爱英, 王玉强, 等. 金沙县城区水旱灾害及防灾减灾措施[J]. 中国防汛抗旱, 2008, 18(1): 18-22, 28. DOI: 10.16867/j.cnki.cfdm.2008.01.006.
- [22] 尚卫平, 戴昱. 基于平滑 ARIMA-LS-SVM 组合模型的股价预测研究[J]. 区域金融研究, 2018(5): 17-23. DOI: 10.3969/j.issn.1674-5477.2018.05.003.
- [23] 卢献健, 晏红波, 梁月吉. 小波分解层数及分量组合对滑坡预测的影响[J]. 桂林理工大学学报, 2016, 36(2): 304-309. DOI: 10.3969/j.issn.1674-9057.2016.02.018.
- [24] 彭荣荣, 刘芸男, 杨冬燕, 等. 临床用血需求的 ARIMA 模型预测[J]. 郑州大学学报(医学版), 2019, 54(6): 874-878. DOI: 10.13705/j.issn.1671-6825.2018.12.166.
- [25] 景志刚, 施国良. 基于小波分析的 LS-SVM-ARIMA 组合模型的黄金价格预测[J]. 黄金, 2017, 38(5): 5-8, 14. DOI: 10.11792/hj20170502.