

doi:10.6041/j.issn.1000-1298.2020.01.015

基于条件植被温度指数的夏玉米生长季干旱预测研究

李俐^{1,2} 许连香^{2,3} 王鹏新^{2,3} 齐璇^{2,3} 王蕾^{2,3}

(1. 中国农业大学土地科学与技术学院, 北京 100083; 2. 农业农村部农业灾害遥感重点实验室, 北京 100083;
3. 中国农业大学信息与电气工程学院, 北京 100083)

摘要: 为验证条件植被温度指数(VTCI)在夏玉米生长季干旱预测中的适用性,以河北中部平原为研究区,应用求和自回归移动平均(ARIMA)模型及季节性求和自回归移动平均(SARIMA)模型,对该地区VTCI时间序列数据进行分析建模预测。首先基于49个气象站点所在像素的VTCI时间序列数据,选取不同长度时间序列建立ARIMA模型,并分析时间序列长度与预测精度间关系,以期时间为时间序列长度选择提供依据;然后选择理想长度的VTCI时间序列数据,分别建立ARIMA模型和SARIMA模型,用于研究区域2017年夏玉米生长季VTCI预测,并分析评价两模型预测精度;最后采用性能较好的ARIMA模型逐像素建模预测,得到2016—2018年9月上旬至下旬VTCI预测结果。结果表明:基于ARIMA模型的VTCI预测精度与时间序列长度未呈现明显的相关关系,但随时间序列长度增加,模型预测精度逐渐趋于稳定;ARIMA模型对干旱的预测精度高于基于SARIMA模型,其1步、2步、3步VTCI预测结果均方根误差较SARIMA模型分别降低0.06、0.07、0.09;ARIMA模型在不同年份夏玉米生长季VTCI 1~3步的预测精度稳定性较好,2016—2018年1步、2步和3步VTCI预测结果绝对误差绝对值大于0.20的像素平均百分比分别为5.84%、6.38%、8.72%。

关键词: 夏玉米; 条件植被温度指数; 求和自回归移动平均模型; 季节性求和自回归移动平均模型; 干旱预测

中图分类号: TP79

文献标识码: A

文章编号: 1000-1298(2020)01-0139-09

OSID:



Drought Forecasting during Maize Growing Season Based on Vegetation Temperature Condition Index

LI Li^{1,2} XU Lianxiang^{2,3} WANG Pengxin^{2,3} QI Xuan^{2,3} WANG Lei^{2,3}

(1. College of Land Science and Technology, China Agricultural University, Beijing 100083, China

2. Key Laboratory of Remote Sensing for Agri-Hazards, Ministry of Agriculture and Rural Affairs, Beijing 100083, China

3. College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China)

Abstract: Drought was an important factor restricting agricultural production and economic development. It was of great significance for promoting economic development and ensuring food security to study the law of occurrence and development of drought and effectively predict the local future drought situation. The purpose was to verify the applicability of vegetation temperature condition index (VTCI) in the drought prediction during summer maize growing season. Taking the central plain of Hebei as the research area and the time series of drought monitoring results of vegetation temperature condition index as the data source, and autoregressive integrated moving average (ARIMA) model and seasonal autoregressive integrated moving average (SARIMA) model were used to forecast agricultural drought. First of all, based on the time series of vegetation temperature condition index of 49 meteorological stations, the VTCI data of different lengths were used to build ARIMA prediction models, and the variation characteristics of ARIMA model prediction accuracy with the increase of VTCI time series length were analyzed. The results showed that there existed no clear dependence between the performance of the model and the training lengths corresponding to the historical datasets of VTCI, but the prediction accuracy of the model

收稿日期: 2019-05-11 修回日期: 2019-07-04

基金项目: 国家重点研发计划重点专项项目(2016YFD0300603-3)

作者简介: 李俐(1976—),女,副教授,博士,主要从事微波遥感及其在农业中的应用研究,E-mail: lilixh@cau.edu.cn

通信作者: 王鹏新(1965—),男,教授,博士,主要从事定量遥感及其在农业中的应用研究,E-mail: wangpx@cau.edu.cn

tended to be stable with the increase of time series length. Then, the VTCI time series data from early July 2010 to late August 2017 was used as modeling data, the ARIMA model and SARIMA model were applied to predict VTCI in September 2017, and the prediction accuracy of the two models was evaluated. The results showed that the prediction accuracy of the ARIMA model was higher than that of the SARIMA model. The root mean square error of the 1-step VTCI prediction of the ARIMA model was 0.06 lower than that of the SARIMA model, and the 2-step prediction was 0.07 lower, and the 3-step prediction was 0.09 lower. Therefore, the ARIMA model was more suitable for the drought prediction during the summer maize growing season in the study area. Finally, the ARIMA model with better performance was modeled pixel by pixel to obtain the VTCI prediction results from early September to late September, 2016—2018. The results showed that the ARIMA model had a good prediction accuracy for 1-step, 2-step and 3-step of VTCI during summer maize growth season in different years. The average percentage of pixels with absolute error larger than 0.20 in 1-step, 2-step and 3-step in 2016—2018 was only 5.84%, 6.38% and 8.72%, respectively.

Key words: summer maize; vegetation temperature condition index; autoregressive integrated moving average model; seasonal autoregressive integrated moving average model; drought forecast

0 引言

干旱是对农业生产影响较大的自然灾害,其波及范围广、持续时间长、危害性大^[1]。及时准确地进行干旱预测对提前采取防灾措施以减小因旱灾造成的经济损失、保证粮食安全具有重要意义^[2]。

干旱指数是衡量干旱程度的重要指标,研究人员提出了许多干旱指数来监测和预测干旱程度^[3-4]。传统干旱指数如帕尔默干旱严重程度指数(Palmer drought severity index, PDSI)、标准化降水指数(Standardized precipitation index, SPI)等^[5],通常利用气象站或水文站等观测数据,虽然数据较为准确,但其精度受限于区域内站点的位置和分布密度,大范围的旱情监测评估应用中,其代表性有待提高^[6]。遥感技术的快速发展使得实时、动态的区域性旱情监测成为可能。常用的遥感干旱监测指数包括植被指数(Vegetation index, VI)、地表温度(Land surface temperature, LST),以及在此基础上开发的条件植被指数(Vegetation condition index, VCI)和条件温度指数(Temperature condition index, TCI)等^[7-8]。有研究表明,植被指数对降水或土壤水分亏缺具有延迟响应^[9],而地表温度虽然对初始水分胁迫具有更大的敏感性^[10],但时空变化受大气、环境状况影响较大,仅利用植被指数或者地表温度进行干旱监测并不理想。故许多学者尝试将植被指数和地表温度结合,利用两者互补特性提供的作物水分亏缺信息来监测旱情^[11]。王鹏新等^[12]在归一化植被指数和地表温度的散点图呈三角形分布的条件下,提出了条件植被温度指数(Vegetation temperature condition index, VTCI)的干旱监测指数,弥补了单一遥感指数的不足,并且成功实现了陕西省关中地区冬小麦生长季的干旱监测和预测^[13]。

常用的预测方法有灰色预测模型、神经网络模型^[14]、加权马尔可夫模型和求和自回归移动平均(Autoregressive integrated moving average, ARIMA)模型等。其中,ARIMA模型作为时间序列分析的主流方法,在很多领域中得到广泛应用^[15]。艾欣等^[16]利用ARIMA模型对电价时间序列进行分析,表明ARIMA模型可提高实时市场的电价预测准确性;窦慧丽等^[17]应用ARIMA模型,以较高精度实现了小波消噪后交通流的实时动态预测。在农业干旱预测方面,田苗等^[18]基于VTCI干旱监测结果,利用季节性求和自回归移动平均(Seasonal autoregressive integrated moving average, SARIMA)模型,实现了冬小麦生长季的短期干旱预测。有研究表明,农业旱情的发生和发展除受降水、温度等影响外,还与农作物自身生理机能有关^[19]。在不同区域、不同作物生育期内,作物对水分胁迫的抵抗力不同,其反映的干旱特征也存在差异^[20]。本文以河北中部平原为研究区域,基于遥感反演获取的VTCI时间序列数据,利用ARIMA模型及季节性ARIMA模型,分别逐像素对该地区的VTCI时间序列进行分析建模预测,分析对比两种模型的预测精度,以获得适合河北中部平原旱情预测的模型;同时,在灌溉类型种植区,验证基于条件植被温度指数(VTCI)的夏玉米生长季对农业旱情预测的有效性。

1 材料与方 法

1.1 研究区概况

选取位于河北中部平原保定市、石家庄市、廊坊市的部分地区以及沧州市和衡水市为研究区(图1),其覆盖范围介于 $114^{\circ}32' \sim 117^{\circ}36' E$, $36^{\circ}57' \sim 39^{\circ}50' N$ 之间,面积约为 $5.3 \times 10^4 \text{ km}^2$ 。该地区属暖温带大陆性季风气候,年平均气温 10°C 以上,主要

耕作制度为冬小麦-夏玉米轮作,是我国重要的玉米生产基地^[21]。然而,夏玉米生育期内气温高且蒸散量大,降水时空分布不均以及水资源的总体不足使得该地区夏玉米生育期内干旱时有发生^[22]。灌浆成熟期是夏玉米产量形成的主要阶段,需要充足的水分作为溶媒把茎叶中的营养物质运输到籽粒中,此时土壤水分状况较生育前期更具有重要的生理意义^[23]。本文重点研究预测该期间(9月)的干旱时空分布情况,以期为当地农业的防灾减灾提供科学指导和依据。

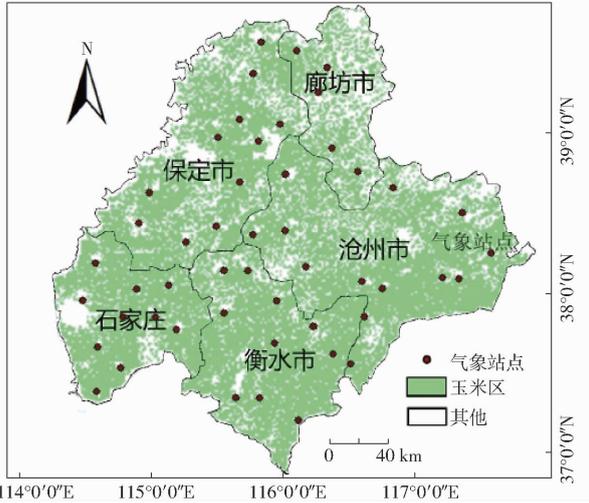


图 1 研究区域位置及气象站点分布图

Fig. 1 Location map of study area and weather stations

1.2 数据获取与处理

条件植被温度指数 (VTCI) 计算式^[24-25]为

$$V = \frac{L_{\max}(N_i) - L(N_i)}{L_{\max}(N_i) - L_{\min}(N_i)} \quad (1)$$

其中 $L_{\max}(N_i) = a + bN_i$ (2)

$L_{\min}(N_i) = a' + b'N_i$ (3)

式中 N_i ——第 i 个像素的归一化植被指数
 $L(N_i)$ ——在研究区域内,某一像素的 NDVI 值为 N_i 时的地表温度

$L_{\max}(N_i)$ 、 $L_{\min}(N_i)$ ——当 NDVI 值为某一特定值 N_i 时研究区内所有像素的地表温度的最大值和最小值,称作热边界和冷边界

a 、 b 、 a' 、 b' ——待定系数,由研究区域的 NDVI 和 LST 的散点图近似得到

选取河北省中部平原 2010—2018 年夏玉米生长季的 Aqua-MODIS 数据,主要包括时间分辨率均为 1 d、空间分辨率均为 1 km 的地表温度产品 MYD11A1 与地表反射率产品 MYD09GA。在进行镶嵌、重采样、投影转换以及裁剪等预处理的基础

上,将这两类 MODIS 数据产品批量处理反演得到研究区域日 LST 产品和日 NDVI 产品,进一步利用最大值合成技术,生成以旬为单位的 NDVI 和 LST 最大值合成产品。将多年某一旬的 NDVI 和 LST 最大值合成产品再一次应用最大值合成技术,生成多年旬尺度 NDVI 和 LST 最大值合成产品;同时,基于最小值合成技术将多年某一旬的 LST 最大值合成产品逐像素取最小值,得到多年旬尺度 LST 最大-最小值合成产品。

利用上述 NDVI 和 LST 合成产品,根据 VTCI 计算方法生成 2010—2018 年每年夏玉米生长季(7—9月)以旬为单位的 VTCI 时间序列数据,共 81 旬。另外,VTCI 的取值范围为 $[0, 1]$,VTCI 值越小,表明作物受水分胁迫程度越重;VTCI 值越大,表明作物受水分胁迫程度较轻或不受水分胁迫。考虑到云雨因素可能造成的某些时段或者某些像素数据的缺失,采用反距离加权插值法^[26]对缺失数据进行插补,以保证 VTCI 数据的完整性。

1.3 研究方法

1.3.1 ARIMA 预测模型

ARIMA(p, d, q) 模型是由 BOX 和 JENKINS 提出的时间序列预测方法,通过对非平稳时间序列进行差分处理获得平稳序列,进而利用自回归移动平均模型 ARMA(p, q) 实现对差分后平稳时间序列未来变化的预测。 p 为自回归阶数, q 为移动平均阶数, d 为差分阶数。利用 ARIMA 模型进行预测的基本步骤为^[27]:

(1) 平稳性检验及平稳化处理:首先检验 VTCI 时间序列 $\{X_t; t = 1, 2, \dots\}$ 的平稳性,若为含有趋势性的非平稳时间序列,对其进行 d 阶差分处理将其转换为平稳序列 $\{x_t\}$,即

$$x_t = \nabla^d X_t \quad (4)$$

式中 ∇^d ——序列经过 d 阶逐期差分

由于 x_t 取值不仅与 VTCI 时间序列自身值有关,而且还与进入系统的随机扰动值有关,故对平稳时间序列 $\{x_t\}$ 拟合 ARMA(p, q) 模型为

$$x_t = \sum_{i=1}^p \phi_i x_{t-i} - \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (5)$$

引入后移算子 B ,则 ARMA(p, q) 模型可简记为

$$\phi(B)x_t = \theta(B)\varepsilon_t \quad (6)$$

其中 $\begin{cases} \phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p \\ \theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q \end{cases} \quad (7)$

式中 θ_i 、 ϕ_i ——模型参数 ε_t ——白噪声序列

(2) 模型定阶:对于平稳化处理后的时间序列,需要对自回归阶数 p 和移动平均阶数 q 进行确定,即实现模型定阶。首先,通过自相关函数

(Autocorrelation function, ACF) 和偏自相关函数 (Partial autocorrelation function, PACF) 的拖尾或截尾特征建立对应的模型,其结构判定的基本准则如表 1 所示,确定 p 和 q 的取值范围。然后,根据 AIC 准则 (Akaike information criterion, AIC) 对 p 和 q 进行优选以保障模型的预测精度,AIC 函数达到最小的模型即为最优模型。AIC 函数定义为

$$A_{ic} = -2\ln L(\hat{\beta}) + 2\omega \quad (8)$$

式中 $L(\hat{\beta})$ ——极大似然函数值
 ω ——模型参数个数

表 1 ARMA 模型定阶基本原则

Tab.1 ARMA model fixed basic principle

模型	自相关函数	偏自相关函数
AR(p)	拖尾	p 阶截尾
MA(q)	q 阶截尾	拖尾
ARMA(p, q)	拖尾	拖尾

(3) 参数估计:模型定阶后,使用极大似然估计法对选定模型中的参数 θ_i, ϕ_i 进行估计。

(4) 模型检验:根据残差序列是否为白噪声序列检验模型是否充分提取序列值的信息。采用正态分布检验法,若残差的自相关函数和偏自相关函数值均落在 95% 的置信区间内,则残差序列为白噪声序列,表明拟合模型有效提取了序列信息。否则,需要重新拟合模型。

(5) 模型预测:经过步骤(1)~(4),即可确定最优预测模型,利用 VTCI 时间序列运行此最优模型实现 VTCI 预测。

1.3.2 SARIMA 预测模型

若非平稳性时间序列不仅含有趋势性变化,还

含有季节性变化,对其进行平稳化处理过程中,需要在进行 d 阶差分的基础上,再进行 D 阶季节性差分以消除季节性变化影响得到平稳序列^[28],模型表示为 ARIMA(p, d, q) (P, D, Q)_s,具体公式为

$$\phi(B) \Phi_s(B) \nabla^d \nabla_s^D X_t = \theta(B) \Theta_s(B) \varepsilon_t \quad (9)$$

其中

$$\begin{cases} \Phi_s(B) = 1 - \Phi_1 B^s - \dots - \Phi_p B^{ps} \\ \Theta_s(B) = 1 - \theta_1 B^s - \dots - \theta_q B^{qs} \end{cases} \quad (10)$$

式中 P ——季节性自回归阶数
 Q ——季节性移动平均阶数
 Φ_i, Θ_i ——模型参数
 ∇_s^D ——序列经过周期为 S 的 D 次季节差分

将 2010 年 7 月上旬—2018 年 8 月下旬的 VTCI 数据作为分析建模数据,2016—2018 年每年 9 月上旬—9 月下旬的 VTCI 数据作为检验数据。逐像素提取多句 VTCI 建模数据组成一维时间序列,分别作为两个模型的输入数据,预测流程如图 2 所示,从 2016—2018 年每年 8 月下旬分别向前 1 步、2 步和 3 步得到 2016—2018 年每年 9 月上旬 1 步预测结果、9 月中旬 2 步预测结果和 9 月下旬 3 步预测结果。

1.4 预测精度评价

将 VTCI 遥感监测结果作为真值,应用绝对误差 (Absolute error, AE)、平均绝对误差 (Mean absolute error, MAE) 与均方根误差 (Root mean square error, RMSE) 评价河北中部平原夏玉米生长季 VTCI 预测结果的精度,计算式为

$$A_E = \hat{X}_i - X_i \quad (11)$$

$$M_{AE} = \frac{1}{N} \sum_{i=1}^N |\hat{X}_i - X_i| \quad (12)$$

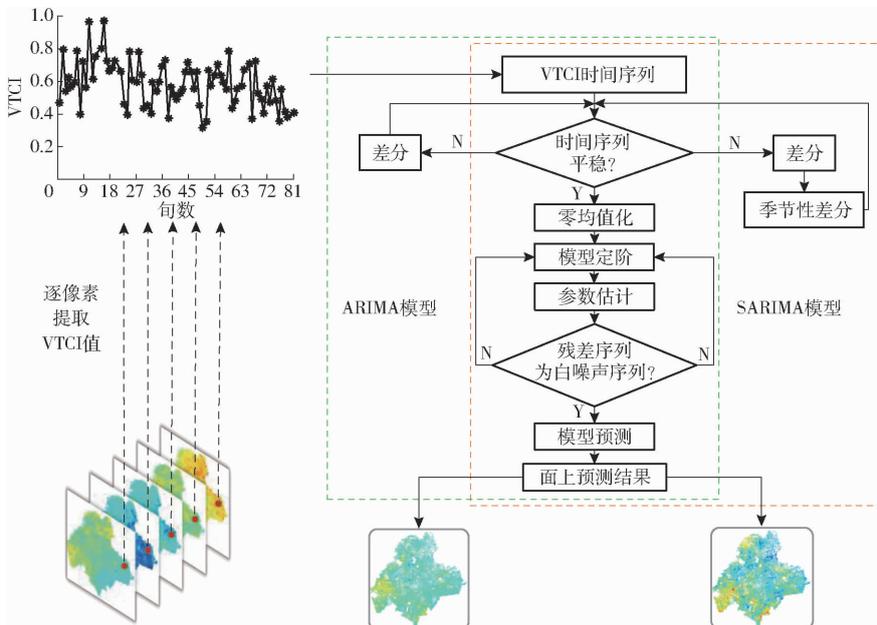


图 2 逐像素建模预测流程图

Fig.2 Pixel-by-pixel forecasting flow chart

$$R_{MSE} = \sqrt{\sum_{i=1}^N \frac{(\hat{X}_i - X_i)^2}{N}} \quad (13)$$

式中 \hat{X}_i ——第 i 个像素的 VTCI 预测值
 X_i ——第 i 个像素的 VTCI 监测值
 N ——研究区域内所有像素点数 (或气象站点总数)

2 结果与分析

2.1 时间序列长度的确定

有研究表明,时间序列长度是影响模型预测准确性的重要因素^[29]。为探究时间序列长度对基于 ARIMA 模型的 VTCI 预测精度的影响,选取均匀分布在河北中部平原地区,包括饶阳、任丘、河间、献县、涿州、雄县、高碑店、固安、永清、霸州、晋州、辛集、藁城、深州、故城等 49 个气象站点 (图 1),利用 49 个气象站点所在像素的 VTCI 时间序列,分别使用 $9n(n=2,3,\dots,8)$ 旬不同长度的 VTCI 数据进行建模预测,并分析基于 ARIMA 模型的 VTCI 预测精度随时间序列长度增加的变化特点。

由表 2 可得,同一时间序列长度时,平均绝对误差随预测步长的增加而增大,表明基于 ARIMA 模型的 VTCI 预测精度随预测步长增加而降低。不同时间序列长度时,模型预测精度随时间序列长度增加上下波动,当序列长度大于 36 旬时,平均绝对误差波动幅度逐渐减小,模型预测精度趋于稳定。综上,考虑到模型预测精度的稳定性,本文分别选取 2010 年 7 月上旬至 2016 年 8 月下旬、2010 年 7 月上旬至

2017 年 8 月下旬、2010 年 7 月上旬至 2018 年 8 月下旬的 VTCI 时间序列数据进行建模,以得到 2016—2018 年每年 9 月的 VTCI 预测结果。

表 2 ARIMA 模型平均绝对误差随时间序列长度变化的统计结果

Tab.2 Statistical results of ARIMA model mean absolute error varied with time series length

时间序列 长度/旬	预测步长		
	1	2	3
18	0.08	0.10	0.10
27	0.06	0.07	0.09
36	0.09	0.10	0.12
45	0.10	0.12	0.13
54	0.10	0.13	0.13
63	0.09	0.10	0.10
72	0.08	0.09	0.10
平均值	0.09	0.10	0.11

2.2 ARIMA 模型及 SARIMA 模型定阶结果分析

根据 ARIMA 模型建模方法,首先分析 49 个气象站点所在像素的 VTCI 时间序列适合的模型结构,再由点及面,逐像素对研究区所有像素的 VTCI 时间序列进行模型定阶。以饶阳为例,其平稳化处理后 VTCI 时间序列的自相关系数及偏自相关系数 (图 3) 未随延迟时期增加迅速衰减至零值附近作小值波动,均表现拖尾特征,表明序列适用 ARMA(p, q) 模型。自相关阶次 p 和移动平均阶次 q 可由低阶向高阶逐步试探, p, q 的取值范围分别取 1~3 和 0~2。依据 AIC 准则进一步进行模型优选,AIC 值最小的模型即为该序列的最优模型。

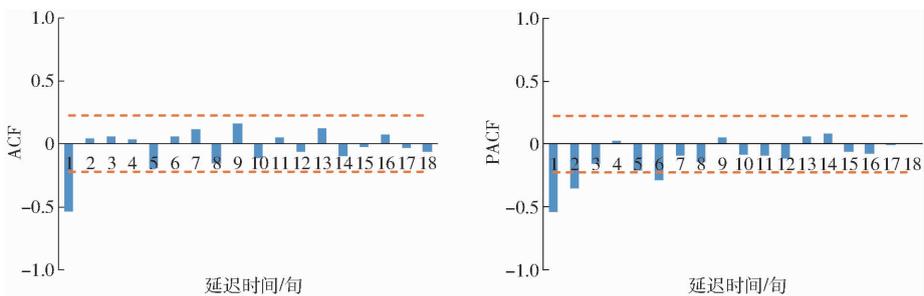


图 3 饶阳气象站差分序列的自相关函数和偏自相关函数

Fig.3 Autocorrelation and partial autocorrelation function graphs of differenced time series of VTCI in Raoyang weather station

逐像素对研究区所有像素进行模型优选,得到 ARIMA 模型和 SARIMA 模型面上定阶结果 (图 4)。可以看出,ARIMA 模型的定阶结果分布具有区域性,未出现“椒盐式”分布现象,表明相邻像素点干旱变化情况具有良好的相关性。廊坊市、沧州市、衡水市及石家庄东部等区域适合 ARIMA(1,1,1) 模型,模型形式较为一致。然而,保定市的模型形式存在 ARIMA(1,1,1)、ARIMA(1,1,2) 及 ARIMA(2,1,1) 等多种情况,表明受客观环境及人为因素的影

响,同一地区不同像素 VTCI 时间序列反映的旱情特性也存在差异性,适用的模型形式可能不同。综上,逐像素确定 ARIMA 模型形式的方法较为合理。SARIMA 模型的定阶结果分布虽呈现了类似的区域性特征,但适用的模型形式更为多样,大部分地区适用的模型为 ARIMA(1,1,1)(0,1,0),以及 ARIMA(3,1,2)(0,1,0)。整体来看,ARIMA 模型定阶结果较 SARIMA 模型区域分布特征更为明确,相邻像素点间干旱变化状况相关性更强。

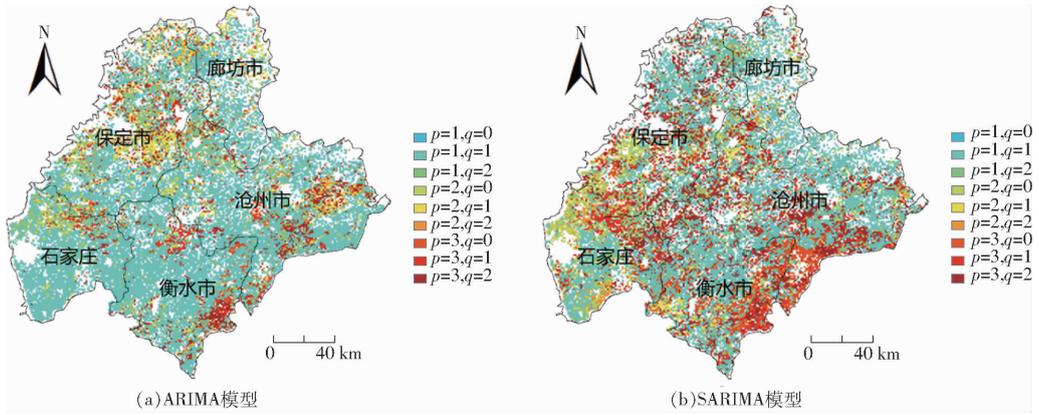


图4 模型定阶结果

Fig.4 Model identification results

2.3 干旱预测结果分析

2.3.1 两种模型 VTCI 预测结果比较

根据 2.2 节中两种模型定阶结果,逐像素进行参数估计和预测,分别得到 2017 年 9 月上旬 1 步预

测结果、9 月中旬 2 步预测结果、9 月下旬 3 步预测结果(图 5)。对于 ARIMA 模型预测结果,从时间上看,各旬 VTCI 均存在较大差异,9 月上旬和下旬预测结果 VTCI 值偏高,特别是中部地区,处于不旱或

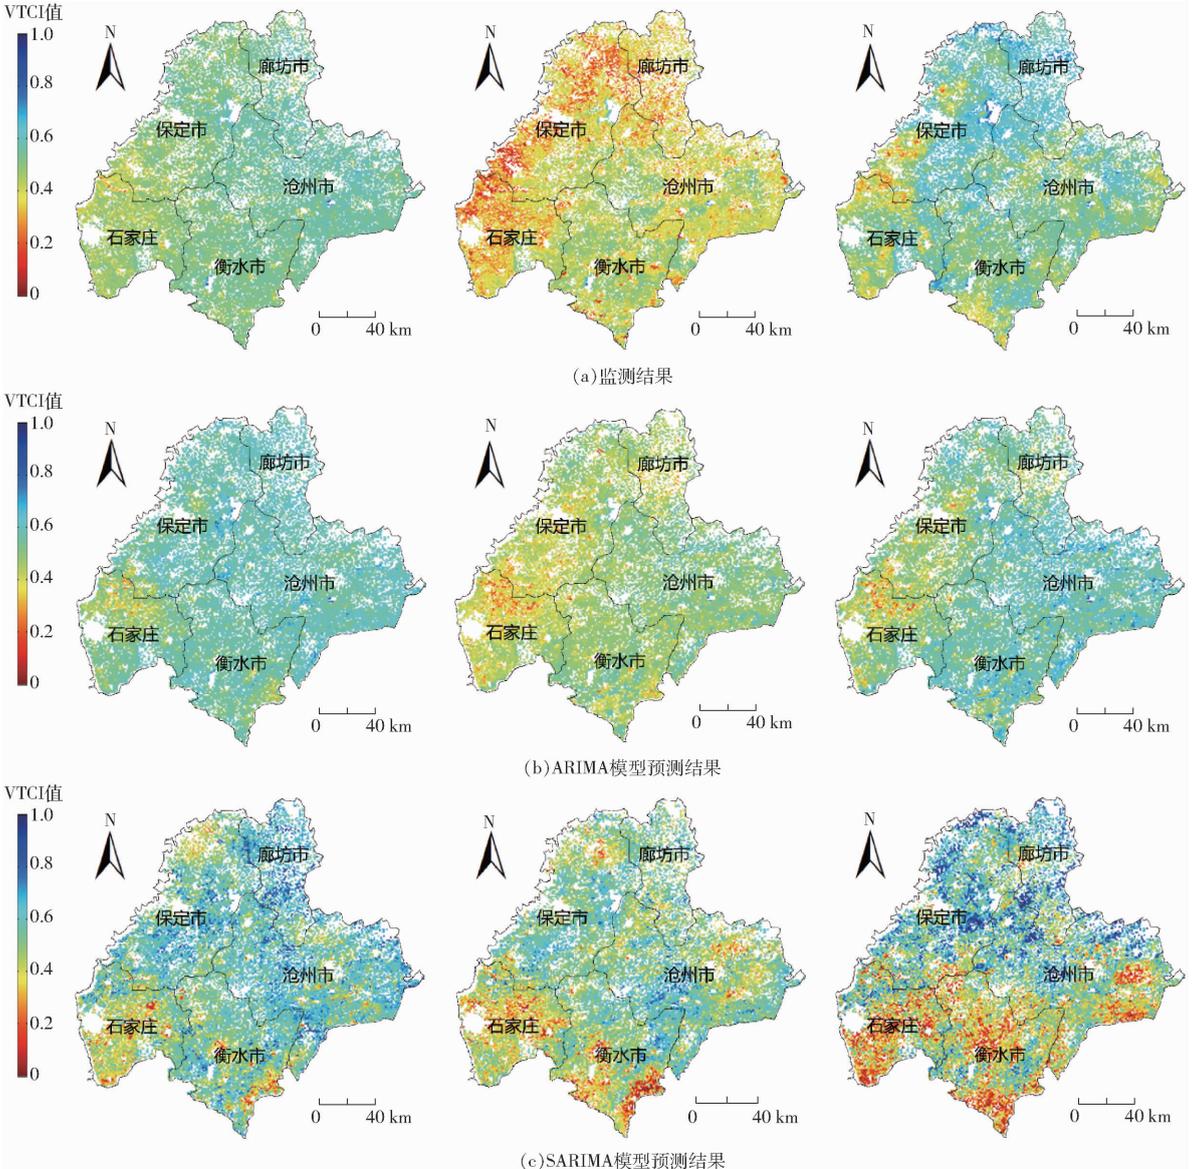


图 5 2017 年 9 月干旱监测结果与预测结果

Fig.5 Drought monitoring results and forecasting results in September 2017

较为湿润的状态；而 9 月中旬预测结果 VTCI 值较上旬和下旬预测结果整体偏低，大部分地区均有旱情发生，虽然与监测结果相比，预测旱情偏轻，但准确反映了河北中部平原地区 9 月上旬到 9 月中旬旱情加重，9 月中旬到 9 月下旬旱情有所缓解的变化趋势。从空间分布来看，河北中部平原西北部 VTCI 值较东南部偏低，特别是保定市和石家庄市东部地区较其他地区干旱严重，与实际监测结果一致。总体来说，三旬的预测结果基本反映了监测结果的特征。

比较来说，SARIMA 模型预测结果与 ARIMA 模型预测结果表征的旱情发展趋势较为相似，9 月中旬大部分地区均有旱情发生，与实际情况吻合。然而，石家庄及衡水市部分地区的 3 步预测结果显示干旱程度加深，受旱面积也呈扩大趋势，与监测结果相差较大，表明 SARIMA 模型 3 步预测结果的不确定较大，不适合更长期的预测。整体来看，SARIMA 模型向前 1~2 步预测较为准确，但向前 3 步预测结果精度稍差。

综上所述，ARIMA 模型较 SARIMA 模型对河北中部平原夏玉米生长季干旱的预测能力更为突出，向前 1~3 旬预测结果均较为准确反映旱情的发展变化趋势。

2.3.2 两种模型干旱预测结果的精度评价

为定量评价两个模型的预测精度，以 2017 年 9 月研究区 VTCI 干旱监测结果为真值，以基于两模型分别向前预测 1 步、2 步和 3 步得到的 2017 年 9 月上旬、中旬和下旬 VTCI 预测结果为预测值，计算得到两模型预测结果与监测结果的绝对误差和绝对误差频数分布图(图 6)。频数大于 500 时，ARIMA 模型 1 步预测结果绝对误差主要分布在 $[-0.05, 0.14]$ ，而 SARIMA 模型 1 步预测结果主要分布在 $[-0.18, 0.27]$ ，较 ARIMA 模型误差分布更为分散。两者峰值虽较为接近，分别为 0.04 和 0.07，但前者峰值频数为 6 022，而后者仅为 4 122。2 步和 3 步预测绝对误差分布规律与 1 步预测相似，ARIMA 模型预测误差分布较 SARIMA 模型更为集中，最大频数对应的绝对误差更接近零值。另外，逐像素计算并统计两模型预测结果与监测结果的平均绝对误差以及均方根误差(表 3)，结果表明，基于 ARIMA 模型 1 步、2 步、3 步 VTCI 预测结果的平均绝对误差和均方根误差均低于基于 SARIMA 模型的误差，平均绝对误差分别降低 0.05、0.05、0.08，均方根误差分别降低 0.06、0.07、0.09。综上，ARIMA 模型预测结果整体上精度更高，预测结果反映的旱情与实际情况更为吻合，可用于研究区夏玉米生长季干旱预测。

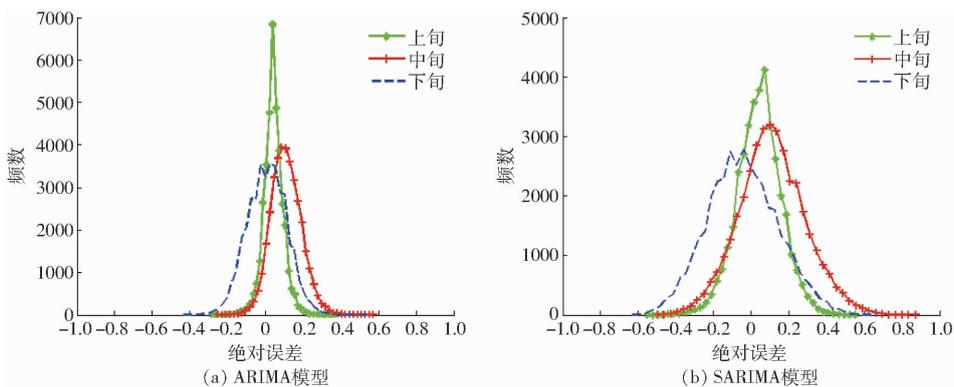


图 6 2017 年 9 月预测结果绝对误差频数分布

Fig. 6 Frequency distributions of absolute errors of forecasting results in September 2017

表 3 ARIMA 模型和 SARIMA 模型预测误差的统计分析

Tab.3 Statistical results of forecasting errors of ARIMA

model and SARIMA model

时间	模型	MAE	RMSE
上旬	ARIMA 模型	0.05	0.07
	SARIMA 模型	0.10	0.13
中旬	ARIMA 模型	0.12	0.14
	SARIMA 模型	0.17	0.21
下旬	ARIMA 模型	0.08	0.10
	SARIMA 模型	0.16	0.19

2.3.3 ARIMA 模型干旱预测结果分析

在比较 ARIMA 模型和 SARIMA 模型预测精度

的基础上，利用精度较高的 ARIMA 模型逐像素建模预测，得到研究区域 2016—2018 年每年 9 月的 VTCI 干旱预测结果，计算统计所有像素绝对误差绝对值及误差在不同区间的分布情况(表 4)，分析不同年份夏玉米生长季 VTCI 的预测精度。结果表明 2016—2018 年各旬 VTCI 预测结果中，2017 年 9 月上旬 1 步预测结果精度最高，仅有约 0.61% 的像素绝对误差绝对值超过 0.20；2016 年 9 月下旬 3 步预测结果精度最低，有大约 17.26% 的像素绝对误差绝对值超过 0.20。其中，2016—2018 年向前 1 步的 VTCI 预测结果中仅有 5.84% 的像素绝对误差绝对值大于 0.20，并且有 62.16% 的像素绝对误差绝对

值小于 0.10,表明向前 1 步的 VTCI 预测精度较高。随着预测步长的增加预测精度略微下降,2 步、3 步预测结果中像素绝对误差绝对值大于 0.20 的百分比分别为 6.38%、8.72%。整体来说,不同年份夏玉米生长季 ARIMA 模型 1 步、2 步、3 步的 VTCI 预测精度均较理想。

表 4 2016—2018 年 VTCI 预测的绝对误差区间的分布

Tab.4 Distribution of absolute error interval of VTCI forecasting from 2016 to 2018 %

预测步长	$ \delta \leq 0.10$	$0.10 < \delta < 0.20$	$ \delta \geq 0.20$
1	62.16	32.00	5.84
2	61.00	32.62	6.38
3	62.61	28.67	8.72

注: $|\delta|$ 表示 VTCI 预测的绝对误差绝对值。

3 讨论

基于遥感反演的 VTCI 干旱监测结果进行夏玉米生长季干旱预测,虽然 VTCI 时间序列在物理意义上具有周期为 9 的季节性,但 SARIMA 模型预测精度整体较 ARIMA 模型低,主要因为河北中部平原夏玉米种植区 VTCI 时间序列未表现明显的季节特性,若对平稳化处理后的序列再进行季节差分,会因为差分过程中信息的损失出现过度差分(简称过差分)的现象,从而影响模型预测精度。

另外,前人研究已表明干旱预测是属于带有强非线性特征的系统问题^[30],ARIMA 模型作为一种

线性预测方法,会忽略 VTCI 时间序列数据中的非线性部分,在准确预测旱情发展趋势方面具有一定劣势。所以在后期的研究中,可利用在非线性系统预测方面具有较强优势的神经网络等方法对 ARIMA 建模过程中的未拟合的非线性误差进行修正,以提高干旱预测的精度。

4 结论

(1) 基于 49 个气象站点所在像素的 VTCI 时间序列,使用不同时间序列长度的 VTCI 数据进行建模预测,结果表明,基于 ARIMA 模型的 VTCI 预测精度与时间序列长度未呈现明显的相关关系,但模型预测精度随序列长度的增加而逐渐趋于稳定。

(2) 将 ARIMA 模型和 SARIMA 模型分别用于河北中部平原 2017 年夏玉米生长季 VTCI 预测,结果表明,ARIMA 模型较 SARIMA 模型 VTCI 预测精度更高,更适合河北中部平原夏玉米生长季的干旱预测,其 1 步、2 步、3 步 VTCI 预测的均方根误差分别为 0.07、0.14、0.10。

(3) 应用 ARIMA 模型逐像素对 2016—2018 年夏玉米生长季 VTCI 进行预测,结果表明,不同年份夏玉米生长季 VTCI 的预测精度稳定性较好,其 2016—2018 年 1 步、2 步和 3 步 VTCI 预测结果绝对误差绝对值大于 0.20 的像素平均占比分别为 5.84%、6.38%、8.72%。

参 考 文 献

- [1] 金菊良,宋占智,崔毅,等. 旱灾风险评估与调控关键技术研究进展[J]. 水利学报,2016,47(3):398-412. JIN Juliang, SONG Zhanzhi, CUI Yi, et al. Research progress on the key technologies of drought risk assessment and control[J]. Journal of Hydraulic Engineering, 2016, 47(3): 398-412. (in Chinese)
- [2] 薛昌颖,马志红,胡程达. 近 40a 黄淮海地区夏玉米生长季干旱时空特征分析[J]. 自然灾害学报,2016,25(2):1-14. XUE Changying, MA Zhihong, HU Chengda. Spatiotemporal characteristics of drought during summer maize growing season in Huang-Huai-Hai area for recent 40 years[J]. Journal of Natural Disasters, 2016, 25(2): 1-14. (in Chinese)
- [3] PARK S, IM J, JANG E, et al. Drought assessment and monitoring through blending of multi-sensor indices using machine learning approaches for different climate regions[J]. Agricultural and Forest Meteorology, 2016, 216: 157-169.
- [4] MISHRA A K, SINGH V P. A review of drought concepts[J]. Journal of Hydrology, 2010, 391(1-2): 202-216.
- [5] 刘小刚,冷险险,孙光照,等. 基于 1961—2100 年 SPI 和 SPEI 的云南省干旱特征评估[J/OL]. 农业机械学报, 2018, 49(12): 236-245, 299. LIU Xiaogang, LENG Xianxian, SUN Guangzhao, et al. Assessment of drought characteristics in Yunnan Province based on SPI and SPEI from 1961 to 2100[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(12): 236-245, 299. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20181229&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2018.12.029. (in Chinese)
- [6] 刘宪锋,朱秀芳,潘耀忠,等. 农业干旱监测研究进展与展望[J]. 地理学报, 2015, 70(11): 1835-1848. LIU Xianfeng, ZHU Xiufang, PAN Yaoshong, et al. Agricultural drought monitor: progress, challenges and prospect[J]. Acta Geographica Sinica, 2015, 70(11): 1835-1848. (in Chinese)
- [7] LIU W T, NEGRÓN JUÁREZ R I. ENSO drought onset prediction in northeast Brazil using NDVI[J]. International Journal of Remote Sensing, 2001, 22(17): 3483-3501.
- [8] JALILI M, GHARIBSHAH J, GHAVAMI S M, et al. Nationwide prediction of drought conditions in Iran based on remote sensing data[J]. IEEE Transactions on Computers, 2013, 63(1): 90-101.
- [9] WANG J, PRICE K P, RICH P M. Spatial patterns of NDVI in response to precipitation and temperature in the central Great Plains[J]. International Journal of Remote Sensing, 2001, 22(18): 3827-3844.
- [10] GOETZ S J. Multi-sensor analysis of NDVI, Multi-sensor analysis of NDVI, surface temperature and biophysical variables at a mixed grassland site [J]. International Journal of Remote Sensing, 1997, 18(1): 71-94.
- [11] PARK S, SEO E, KANG D, et al. Prediction of drought on pentad scale using remote sensing data and MJO index through random forest over east Asia[J]. Remote Sensing, 2018, 10(11): 1181.

- [12] 王鹏新, 龚健雅, 李小文. 条件植被温度指数及其在干旱监测中的应用[J]. 武汉大学学报(信息科学版), 2001, 26(5): 412-418.
WANG Pengxin, GONG Jianya, LI Xiaowen. Vegetation temperature condition index and its application for drought monitoring [J]. Geomatics and Information Science of Wuhan University, 2001, 26(5): 412-418. (in Chinese)
- [13] 韩萍, 王鹏新, 张树誉, 等. 基于条件植被温度指数的干旱预测研究[J]. 武汉大学学报(信息科学版), 2010, 35(10): 1202-1206, 1259.
HAN Ping, WANG Pengxin, ZHANG Shuyu, et al. Drought forecasting with vegetation temperature condition index [J]. Geomatics and Information Science of Wuhan University, 2010, 35(10): 1202-1206, 1259. (in Chinese)
- [14] 陈英义, 程倩倩, 成艳君, 等. 基于 GA-BP 神经网络的池塘养殖水温短期预测系统[J/OL]. 农业机械学报, 2017, 48(8): 172-178.
CHEN Yingyi, CHENG Qianqian, CHENG Yanjun, et al. Short-term prediction system of water temperature in pond aquaculture based on GA-BP neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(8): 172-178. http://www.jcsam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20170819&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2017.08.019. (in Chinese)
- [15] 吴静, 李振波, 朱玲, 等. 融合 ARIMA 模型和 GAWNN 的溶解氧含量预测方法[J/OL]. 农业机械学报, 2017, 48(增刊): 205-210, 204.
WU Jing, LI Zhenbo, ZHU Ling, et al. Hybrid model of ARIMA model and GAWNN for dissolved oxygen content prediction[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(Supp.): 205-210, 204. http://www.jcsam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=2017s033&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2017.S0.033. (in Chinese)
- [16] 艾欣, 周志宇, 魏妍萍, 等. 基于自回归积分滑动平均模型的可转移负荷竞价策略[J]. 电力系统自动化, 2017, 41(20): 26-31, 104.
AI Xin, ZHOU Zhiyu, WEI Yanping, et al. Bidding strategy for time-shiftable loads based on autoregressive integrated moving average model[J]. Automation of Electric Power Systems, 2017, 41(20): 26-31, 104. (in Chinese)
- [17] 窦慧丽, 刘好德, 吴志周, 等. 基于小波分析和 ARIMA 模型的交通流预测方法[J]. 同济大学学报(自然科学版), 2009, 37(4): 486-489, 494.
DOU Huili, LIU Haode, WU Zhizhou, et al. Study of traffic flow prediction based on wavelet analysis and autoregressive integrated moving average model[J]. Journal of Tongji University(Natural Science), 2009, 37(4): 486-489, 494. (in Chinese)
- [18] 田苗, 王鹏新, 韩萍, 等. 基于 SARIMA 模型和条件植被温度指数的干旱预测[J/OL]. 农业机械学报, 2013, 44(2): 109-116.
TIAN Miao, WANG Pengxin, HAN Ping, et al. Drought forecasts based on SARIMA models and vegetation temperature condition index[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(2): 109-116. http://www.jcsam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20130221&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2013.02.021. (in Chinese)
- [19] SWAIN S, WARDLOW B D, NARUMALANI S, et al. Assessment of vegetation response to drought in nebraska using Terra-MODIS land surface temperature and normalized difference vegetation index[J]. GIScience & Remote Sensing, 2011, 48(3): 432-455.
- [20] 黄友昕, 刘修国, 沈永林, 等. 农业干旱遥感监测指标及其适应性评价方法研究进展[J]. 农业工程学报, 2015, 31(16): 186-195.
HUANG Youxin, LIU Xiuguo, SHEN Yonglin, et al. Advances in remote sensing derived agricultural drought monitoring indices and adaptability evaluation methods[J]. Transactions of the CSAE, 2015, 31(16): 186-195. (in Chinese)
- [21] 薛昌颖, 刘荣花, 马志红. 黄淮海地区夏玉米干旱等级划分[J]. 农业工程学报, 2014, 30(16): 147-156.
XUE Changying, LIU Ronghua, MA Zhihong. Drought grade classification of summer maize in Huang-Huai-Hai area[J]. Transactions of the CSAE, 2014, 30(16): 147-156. (in Chinese)
- [22] 张金龙, 刘学锋, 于长文. 河北省干旱分布特征和变化规律分析[J]. 干旱区研究, 2012, 29(1): 41-46.
- [23] 贾银锁, 郭进考. 河北夏玉米与冬小麦一体化种植[M]. 北京: 中国农业科学技术出版社, 2009.
- [24] 王鹏新, WAN Zhengming, 龚健雅, 等. 基于植被指数和土地表面温度的干旱监测模型[J]. 地球科学进展, 2003, 18(4): 527-533.
WANG Pengxin, WAN Zhengming, GONG Jianya, et al. Advances in drought monitoring by using remotely sensed normalized difference vegetation index and land surface temperature products[J]. Advances in Earth Science, 2003, 18(4): 527-533. (in Chinese)
- [25] 孙威, 王鹏新, 韩丽娟, 等. 条件植被温度指数干旱监测方法的完善[J]. 农业工程学报, 2006, 22(2): 22-26.
SUN Wei, WANG Pengxin, HAN Lijuan, et al. Further improvement of the approach to monitoring drought using vegetation and temperature condition indexes from multi-years' remotely sensed data[J]. Transactions of the CSAE, 2006, 22(2): 22-26. (in Chinese)
- [26] 樊子德, 李佳霖, 邓敏. 顾及多因素影响的自适应反距离加权插值方法[J]. 武汉大学学报(信息科学版), 2016, 41(6): 842-847.
FAN Zide, LI Jialin, DENG Min. An adaptive inverse-distance weighting spatial interpolation method with the consideration of multiple factors[J]. Geomatics and Information Science of Wuhan University, 2016, 41(6): 842-847. (in Chinese)
- [27] 左志宇, 毛罕平, 张晓东, 等. 基于时序分析法的温室温度预测模型[J]. 农业机械学报, 2010, 41(11): 173-177, 182.
ZUO Zhiyu, MAO Hanping, ZHANG Xiaodong, et al. Forecast model of greenhouse temperature based on time series method [J]. Transactions of the Chinese Society for Agricultural Machinery, 2010, 41(11): 173-177, 182. (in Chinese)
- [28] SHARAFI M, GHAEM H, TABATABAEE H R, et al. Forecasting the number of zoonotic cutaneous leishmaniasis cases in south of Fars province, Iran using seasonal ARIMA time series method[J]. Asian Pacific Journal of Tropical Medicine, 2017, 10(1): 79-86.
- [29] 徐敏, 谢倩倩. 时间序列长度对基于 ARIMA 模型的月径流预报效果的影响分析[J]. 长江大学学报(自科版), 2014, 11(34): 6-10, 3.
XU Min, XIE Qianqian. Influence of time series length on the effect of monthly runoff forecast based on ARIMA model[J]. Journal of Yangtze University(Nat. Sci. Edit.), 2014, 11(34): 6-10, 3. (in Chinese)
- [30] 侯姗姗, 王鹏新, 田苗. 基于相空间重构与 RBF 神经网络的干旱预测模型[J]. 干旱地区农业研究, 2011, 29(1): 224-230.