

LSTM 模型在京津冀干旱预测应用中的研究

胡小枫^{1,2}, 赵安周^{1,2,3}, 相恺政^{1,2}, 张向蕊^{1,2}

(1. 河北工程大学 矿业与测绘工程学院, 河北 邯郸 056038;

2. 邯郸市自然资源空间信息重点实验室, 河北 邯郸 056038;

3. 中国科学院 地理科学与资源研究所资源与环境信息系统国家重点实验室, 北京 100101)

摘要: 在多时间尺度上对京津冀的旱情进行准确地预测可为当地抗旱提供有效支撑。基于 1961—2019 年京津冀 22 个气象站点的降水、气温、平均湿度等多个气象因子数据, 计算标准化降水蒸散发指数 (standardized precipitation evapotranspiration index, SPEI), 并构建长短时记忆神经网络模型 (long short-term memory model, LSTM) 对多时间尺度的 SPEI (SEPI-3、SPEI-6、SPEI-9、SPEI-12 和 SPEI-24) 进行时空预测。采用平均绝对误差 (MAE)、均方根误差 (RMSE) 和决定系数 (R^2) 对预测模型进行精度评估。结果表明在唐山气象站上, LSTM 模型对多时间尺度 SPEI (SEPI-3、SPEI-6、SPEI-9、SPEI-12 和 SPEI-24) 值的预测效果较好。在时间序列预测方面, LSTM 模型的预测精度随着 SPEI 的时间尺度增加而逐渐提高, 其中 LSTM 模型在 3 个月和 24 个月 SPEI 时间尺度上的 MAE 分别为 0.473 和 0.197, RMSE 分别为 0.627 和 0.260, R^2 分别为 0.604 和 0.935。在空间分布预测上, LSTM 模型对 2019 年京津冀季节和年时间尺度上的 SPEI 预测值与实际值在空间分布上相似, 说明 LSTM 模型能够较为精确地预测京津冀干旱的空间分布。

关键词: 干旱预测; LSTM 模型; SPEI; 京津冀

中图分类号: P426.616

文献标志码: A

文章编号: 1006-4710(2022)03-0356-10

Evaluating the application of LSTM model for drought forecasting in Beijing-Tianjin-Hebei region

HU Xiaofeng^{1,2}, ZHAO Anzhou^{1,2,3}, XIANG Kaizheng^{1,2}, ZHANG Xiangrui^{1,2}

(1. School of Mining and Geomatics, Hebei University of Engineering, Handan 056038, China;
2. Key Laboratory of Natural Resources and Spatial Information, Handan 056038, China;
3. Laboratory of Resources and Environmental Information System, Institute of Geographic Sciences and Natural Resources Research, Chinese Academy of Science, Beijing 100101, China)

Abstract: Accurate prediction of drought condition in Beijing-Tianjin-Hebei on multiple time scales can provide effective support for local drought resistance. Based on the data multiple meteorological factors such as precipitation, temperature and mean humidity from 22 meteorological stations in Beijing-Tianjin-Hebei region from 1961 to 2019, the standardized precipitation evapotranspiration index (SPEI) is calculated, the long short-term memory models (LSTM) constructed to forecast the time and space of SPEI (including SPEI-3, SPEI-6, SPEI-9, SPEI-12 and SPEI-24) at multi-temporal scales. The accuracy of all prediction models are determined by mean absolute error (MAE), root mean square error (RMSE) and decision coefficient (R^2). The results show that LSTM model has a well predictive effect on multi-time scales SPEI (SPEI-3, SPEI-6, SPEI-9, SPEI-12 and SPEI-24) values of meteorological station in Tangshan. In terms of

收稿日期: 2021-11-09; 网络出版日期: 2022-03-31

网络出版地址: <https://kns.cnki.net/kcms/detail/61.1294.N.20220330.1151.006.html>

基金项目: 国家自然科学基金资助项目(42171212, 42071246); 河北省普通高等学校青年拔尖人才计划资助项目(BJ2018043); 2021 年河北省硕士研究生创新资助项目(CXZZSS2021089); 资源与环境信息系统国家重点实验室开放基金资助项目

第一作者: 胡小枫, 男, 硕士生, 研究方向为干旱监测与预测。E-mail: 729420832@qq.com

通信作者: 赵安周, 男, 博士, 副教授, 研究方向为城市扩张对生态环境影响。E-mail: zhaoanzhou@126.com

time series forecast, the prediction accuracy of LSTM model for SPEI is increased with the increase of time scale. MAE values of LSTM model in SPEI-3 and SPEI-24 are 0.473 and 0.197, RMSE values are 0.627 and 0.260, R^2 values are 0.604 and 0.935 respectively. In terms of spatial distribution forecast, the predicted value of LSTM model on seasonal and annual time scales of Beijing-Tianjin-Hebei region in 2019 is very similar to the actual value of SPEI, indicat that LSTM model can accurately forecast the spatial distribution of drought in Beijing-Tianjin-Hebei region.

Key words: drought forecast; LSTM; SPEI; Beijing-Tianjin-Hebei region

干旱作为世界上最常见的自然灾害之一,其发生频率高、持续时间长、波及范围广,严重阻碍了全球社会经济发展和农业生产^[1-2]。进入21世纪,随着全球气候变暖,干旱发生的频率和强度均有增加的趋势,对生态系统和粮食作物产量的影响日益加重^[3]。据统计,自1950年以来,全国年均受旱面积为 $2.16 \times 10^5 \text{ km}^2$,因干旱而造成的粮食损失达到 $1.58 \times 10^{10} \text{ kg}$,对我国粮食安全造成了严重的威胁^[4]。因此,加强对干旱预测方面的研究,及时准确地提供干旱的发生时间和过程,对当地有关部门预防和减少干旱灾害具有重要的意义^[5-7]。

干旱指数作为定量评价干旱程度的有效手段,是干旱评估预测研究的基础之一^[8-9]。国内外常用的干旱分析指数有:Palmer干旱指数(Palmer drought severity index, PDSI)、综合气象干旱指数(comprehensive index, CI)、标准化降水指数(standardized precipitation index, SPI)和标准化降水蒸散发指数(standardized precipitation evapotranspiration index, SPEI)等^[10]。其中SPEI不仅具有多尺度、计算较为简便的优点,且考虑了对蒸散发的需求等特征,因此可以表征不同类型的干旱,是干旱评估预测中应用最广泛的指数之一^[11-12]。张露等^[13]利用不同时间尺度的SPEI和重标极差R/S等方法深入剖析了锡林河地区多年干旱演变趋势,并较为准确地预测了该地区未来旱情发展特征。Drumond等^[14]利用长时间序列多尺度SPEI对南美洲东部进行干旱评估分析,发现SPEI能较为准确地监测出该区域的干旱发生事件和旱情发展过程。

在干旱预测研究方面,常用的预测模型包括ARIMA、人工神经网络(artificial neural networks, ANN)、循环神经网络(recurrent neural network, RNN)和长短时记忆神经网络(long short-term memory model, LSTM)等^[15]。其中,LSTM模型由于加入了遗忘、输入和输出这三种门来分别控制细胞状态中所要忘记、更新和输出的信息,因此被广泛应用在长时间序列预测中^[16]。目前已有学者采用该模型对长时间序列的干旱进行了预测。刘新等^[17]基于青藏高原长时间序列降水量数据资料,采

用LSTM模型对该地区的重要干旱变量月降水量进行了预测,并与传统的RNN、ARIMA预测模型进行精度对比,发现LSTM模型预测精度最高。张建海等^[16]将线性ARIMA模型与非线性LSTM模型结合,构建出ARIMA-LSTM预测模型对青海省的多尺度SPI指数进行预测,发现ARIMA-LSTM模型的预测精度随着SPI的时间尺度增加而逐渐提高。Dikshit等^[18]将水文气象变量作为预测因子,用随机森林、ANN和LSTM模型分别对澳大利亚新南威尔士州的1个月和3个月两种不同尺度的SPEI进行预测,发现LSTM预测模型对2种不同尺度的SPEI预测精度最高。但总体来看,LSTM在干旱预测中的应用尚处于起步阶段,大多数研究都是基于单一变量或单一时间尺度上对干旱分析指数进行预测,较少有基于多个干旱变量因子,并在多时间尺度上对干旱进行较为准确地预测分析^[19]。

鉴于此,本文以我国干旱频发的京津冀为例,基于其22个气象站点中的月最高气温、月最低气温、月降水量等多个干旱变量因子,在3、6、9、12和24个月多个时间尺度上用LSTM模型对SPEI进行预测研究,以期为京津冀地区的农业生产、干旱评估和预测提供科学参考依据。

1 数据与方法

1.1 研究区概况

京津冀地处 $36.1^\circ\text{N} \sim 42.6^\circ\text{N}, 113.4^\circ\text{E} \sim 119.8^\circ\text{E}$,总面积为 $2.18 \times 10^5 \text{ km}^2$ ^[20],包括北京、天津两个直辖市和河北省11个地级市。该地区东临渤海湾,西倚太行山,南面华北平原,北靠燕山山脉,地势由东北向西南倾斜,平均海拔500 m以上^[21]。京津冀气候类型为典型的温带半湿润半干旱大陆性气候,春季干旱大风,夏季高温多雨,冬季寒冷干燥^[22]。该地区降水波动较大且分布不均,年降水量为400~800 mm,70%以上的降水量集中在夏季。枯水年和丰水年的降水量相差4~5倍,严重时差值能达到15~20倍,以致京津冀境内经常出现旱灾,常有“十年九旱”之说^[23]。

1.2 数据来源及处理

本文所采用的京津冀22个国家基本气象站(见

图1)来源于中国气象数据共享网(<http://www.nmic.cn/>),并选取了其中时间跨度为1961—2019年的逐月降水、最高气温、最低气温、平均气温等气象数据资料。这些数据经过了严格的质量控制和修订,包括采用其相邻站点的同期数据插值对缺失数据修补、错误数据修订以及筛选并剔除无效数据来确保数据的有效性和采集时间的连续性^[24]。这些站点气象数据主要用于后续的 SPEI 计算和预测模型构建。

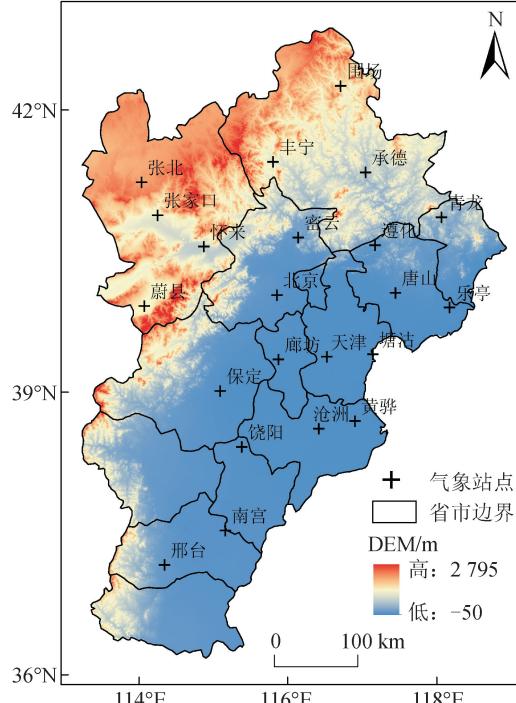


图1 京津冀地区地理位置、高程与气象站点空间分布
Fig. 1 Geographical location, elevation and spatial distribution of meteorological stations in Beijing-Tianjin-Hebei region

注:底图来自国家自然资源部标准地图服务网站,
审图号为GS(2015)732,底图无修改。

1.3 研究方法

1.3.1 SPEI 计算

SPEI 计算原理和步骤较为简单,即通过衡量降水量和蒸散量的差值与平均状态的偏离程度来表征干湿状态^[25-26]。参照国家干旱分级标准^[27]可将 SPEI 分为以下等级,分级结果见表 1。

表 1 SPEI 干旱分级标准

Tab. 1 Drought classification of SPEI

等级	类型	值
1	无旱	$-0.5 \leq \text{SPEI}$
2	轻旱	$-1.0 \leq \text{SPEI} < -0.5$
3	中旱	$-1.5 \leq \text{SPEI} < -1.0$
4	重旱	$-2.0 \leq \text{SPEI} < -1.5$
5	特旱	$\text{SPEI} < -2.0$

本文根据京津冀 22 个气象站点中的气温和降

水数据,计算 1961—2019 年各气象站点 3、6、9、12 和 24 个月多个时间尺度的 SPEI,将其作为后续干旱预测模型的目标量来构建模型,其具体计算方式见如下。

1) 对潜在蒸散发 PET 采用 Thormthwaite 方法^[28]进行计算:

$$PET = 16B \times \left(\frac{10T}{H}\right)^A \quad (1)$$

式中:T 为月平均温度;B 为依据气象站点的纬度而计算的修正系数;H 为年热量指数;A 是以 H 为基础的系数。

2) 计算逐月降水与蒸散发的差值 D_i 为:

$$D_i = PRE_i - PET_i \quad (2)$$

式中: PRE_i 为逐月降水量; PET_i 为月潜在蒸散发量。

3) 对所构建序列的 D_i 采用带有 3 个参数的 log-logistic 概率分布进行拟合:

$$F(x) = \left[1 + \left(\frac{\alpha}{x - \gamma}\right)^\beta\right]^{-1} \quad (3)$$

式中 α, β, γ 采用 L-矩估计方法进行计算,具体计算方法见参考文献[10]。

4) 将累积概率密度进行标准化,得到相应的 SPEI 值:

$$P = 1 - F(x) \quad (4)$$

当累积概率 $P \leq 0.5$ 时,

$$W = \sqrt{-2 \ln(P)} \quad (5)$$

$$SPEI = W - \frac{a_0 - a_1 W + a_2 W^2}{1 + b_0 W + b_1 W^2 + b_2 W^3} \quad (6)$$

当 $P > 0.5$ 时, P 取值为 $1 - P$, SPEI 计算式为:

$$W = \sqrt{-2 \ln(1 - P)} \quad (7)$$

$$SPEI = -\left(W - \frac{a_0 - a_1 W + a_2 W^2}{1 + b_0 W + b_1 W^2 + b_2 W^3}\right) \quad (8)$$

式中: $a_0 = 2.515517$, $a_1 = 0.802853$, $a_2 = 0.010328$, $b_0 = 1.432788$, $b_1 = 0.189269$, $b_2 = 0.001308$ 。

1.3.2 LSTM 模型

LSTM 模型是循环神经网络的变体,常用于预测长时间序列数据,而 LSTM 神经网络的核心为隐藏层,由多个细胞单元构成,细胞单元的结构见图 2^[29]。LSTM 神经网络细胞单元包括遗忘、输入和输出门,它们通过分别控制细胞状态中所要忘记、更新和输出的信息来使 LSTM 具有长期记忆信息的能力^[30],其具体的工作机制如下:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (9)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (10)$$

$$\widetilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (11)$$

$$C_t = f_t * C_{t-1} + i_t * \widetilde{C}_t \quad (12)$$

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (13)$$

$$h_t = O_t * \tanh(C_t) \quad (14)$$

式中: f_t 、 i_t 、 O_t 分别为遗忘、输入和输出门; W_f 、 W_i 、 W_o 分别为遗忘、输入和输出门的权重矩阵; W_c 为本输入单元权重矩阵; b_f 、 b_i 、 b_o 为相应遗忘、输入、输出门的偏置; b_c 为本输入单元的偏置; x_t 和 x_{t-1} 为上一细胞单元和本细胞单元的输入值; h_{t-1} 与 h_t 为上一细胞单元和本细胞单元的输出值; C_{t-1} 和 C_t 分别为上一细胞和本细胞单元结构状态; \widetilde{C}_t 为要加入LSTM神经网络的细胞结构状态; σ 和tanh分别代表sigmoid函数和双曲正切激活函数,它们的详细公式见文献[31]。

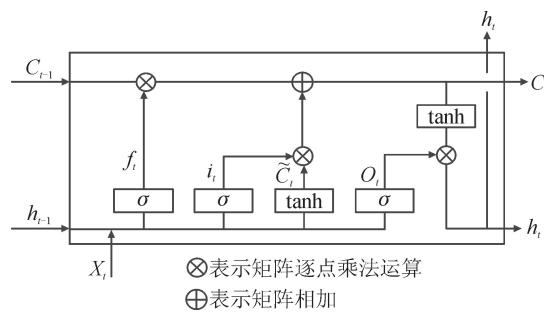


图 2 LSTM 神经网络细胞结构图

Fig. 2 Cell structure of LSTM neural network

1.3.3 模型评价指标

本文选取平均绝对误差(MAE)、均方根误差(RMSE)和决定系数(R^2)作为预测模型的精度评价指标,其具体计算式如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (15)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (16)$$

$$R^2 = \frac{\left[\sum_{i=1}^n (y_i - \bar{y}_i)(\hat{y}_i - \bar{\hat{y}}_i) \right]^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2 \sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}}_i)^2} \quad (17)$$

式中: y_i 、 \hat{y}_i 分别代表实际值和模型的模拟值; \bar{y}_i 、 $\bar{\hat{y}}_i$ 分别代表实际值平均值和模型的模拟值平均值; n 为样本总个数。其中,当RMSE与MAE越接近0和 R^2 越接近1时代表模型模拟值与实际值越接近,即模型的预测精度越高。

2 结果与分析

2.1 LSTM 建模流程

根据京津冀 22 个气象站点中 1961—2019 年的月最高气温、月最低气温、月平均气温、月降水量、月平均相对湿度、月平均气压和月日照时长这 7 种气象数据作为预测因子,对各气象站点 3、6、9、12 和 24 个月多尺度的 SPEI 值构建 LSTM 模型进行预测。因气象站点较多,本文以唐山站为例来阐述 LSTM 建模过程,其具体流程见图 3。

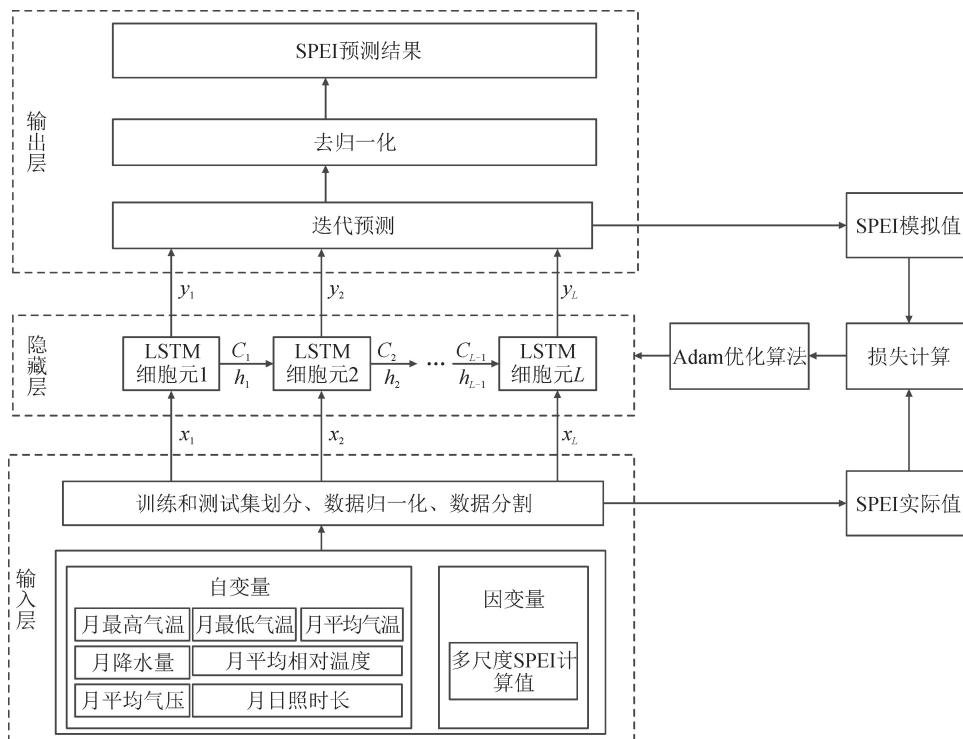


图 3 LSTM 预测模型构建流程图

Fig. 3 Flowchart for constructing the LSTM prediction model

首先采用最大最小法将构建好的数据集进行数据归一化到 $[0,1]$ 之间,用来消除数据之间因为数量级相差较大而造成的误差,其中最大最小法的详细计算原理见文献[18]。数据归一化后,对数据集进行划分和分割,将1961—2019年长时间序列的数据集按照7:3的划分方式划分成训练集(1961—2012)和预测测试集(2013—2019)。并将训练集分割成3D形式的张量,形状为[Sample_size(1961—2012), timestep, features_n(7)]。Sample_size为训练数据,设置到2012; timestep为时间窗口步长,用于预测SPEI的时间窗口大小。经过多次实验将3、6、9、12和

24个月尺度的SPEI的timestep分别设为2、5、8、11和23,即分别用过去2、5、8、11和23个月的参数预测各个尺度下一个月的SPEI。features_n为预测特征的个数,在此研究中将features_n设为7。

在对数据进行分割后,将划分好的训练数据集输入LSTM模型进行参数率定,并对模型进行训练。本文所采用的是基于python 3.7的TF 2.0(TensorFlow 2.0)框架搭建LSTM预测模型,该框架是用节点来施加数学操作,线表示节点之间输入/输出关系的一种基于数据流程图进行数值计算的开源软件库^[32]。经过多次实验,最终模型构建的详细参数见表2。

表2 LSTM神经网络的模型构建参数

Tab. 2 Construction parameters of LSTM neural network model

网路层数	迭代次数	批尺寸	损失函数	舍弃率	优化算法	学习率	监视指标
5	400	32	MSE	0.3	Adam	0.001	MSE

为了防止模型出现过拟合,本文在LSTM模型中加入了Dropout算法层,以此抑制节点之间的协

调适应性,使模型具有较好的泛化能力^[33]。该算法的具体工作原理见图4。

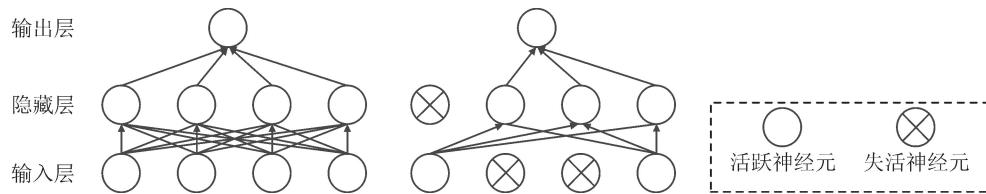


图4 Dropout算法示意
Fig. 4 Dropout schematic

经过模型参数率定后,将训练集数据进行输入LSTM模型得到SPEI的模拟值,并与SPEI实际值求得损失误差,通过模型设定好的Adam优化算法^[34],并经过反复的迭代更新网络模型的权重参数矩阵,降低损失函数值,完成模型的训练和构建过程。随后,利用预测测试数据集对LSTM预测模型进行验证,即将预测测试集输入模型中得到SPEI模拟值,再将SPEI模拟值进行去归一化得到SPEI预测值并将其与SPEI的实际值进行比较,其结果见表3和图5。

表3 唐山站预测测试集上各尺度SPEI预测精度结果

Tab. 3 Prediction accuracy results of multi-time scale SPEI on the forecast test set at Tangshan station

时间尺度	MAE	RMSE	R ²
3	0.499	0.657	0.557
6	0.397	0.592	0.594
9	0.315	0.466	0.720
12	0.240	0.321	0.848
24	0.224	0.297	0.869

可以看出,在预测测试集上,唐山站的各尺度SPEI预测值与SPEI实际值较为吻合,并且随着时间尺度的增加,吻合度越高,并且SPEI的预测精度也是随着时间尺度的增加而逐渐提高,其中SPEI在3个月时间尺度上预测精度最低(MAE=0.499, RMSE=0.657, R²=0.557),在24个月时间尺度上预测精度最高(MAE=0.224, RMSE=0.297, R²=0.869)。

2.2 LSTM模型预测精度评定

按照2.1小节分别对京津冀22个气象站点在多时间尺度上构建LSTM预测模型后,分别对这些模型的预测精度在不同时间尺度上进行评定,评定结果见图6。由图6可知,在多个时间尺度下,LSTM模型的总体预测精度较好,R²均在0.503以上,MAE与RMSE分别均在0.531和0.730以下。LSTM模型预测精度最低的站点有张北、围场和邢台,其中张北和围场的LSTM模型分别在3和6个月时间尺度下预测精度最低,邢台的LSTM模型在9、12和24个月时间尺度下预测精度最低。而LSTM模

型预测精度最高的站点有遵化、蔚县和沧州,在3、12和24个月时间尺度上遵化的LSTM模型预测精度最高,而蔚县和沧州的LSTM模型则分别在6和9个月时间尺度下预测精度最高,并且在京津冀的各个站点上都

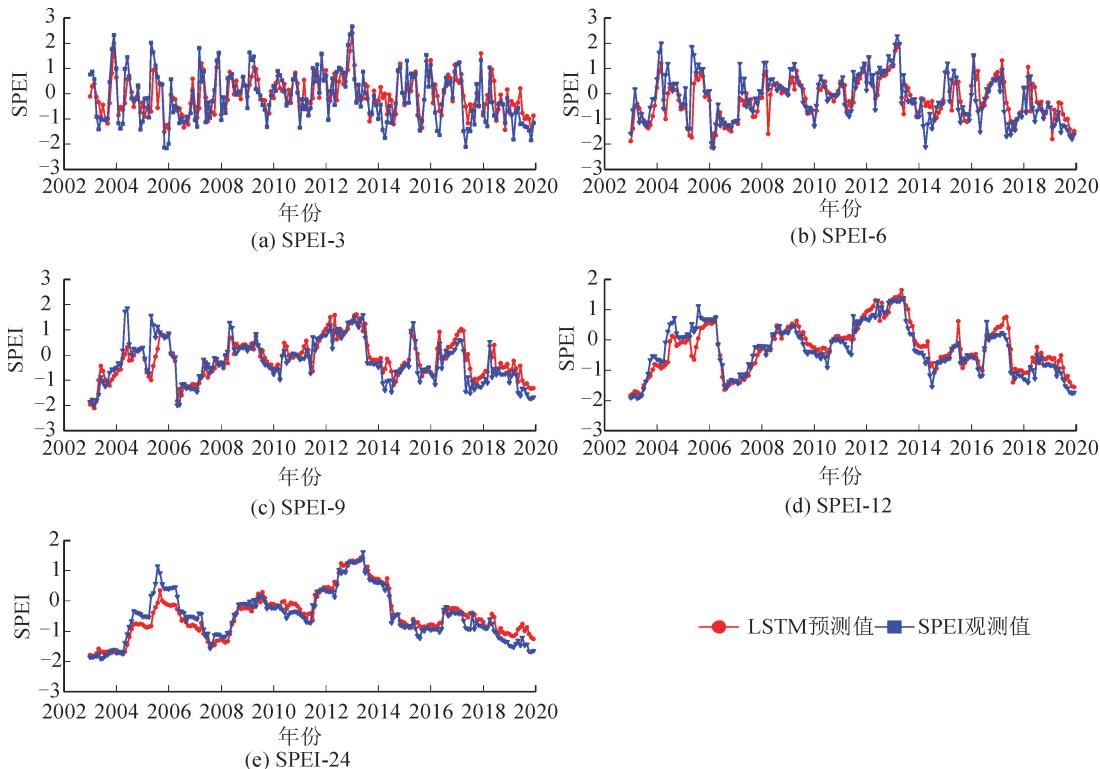


图5 唐山站LSTM模型对多尺度 SPEI 值的预测(2003—2019)

Fig. 5 Forecast of multi-time scale SPEI value of LSTM model at Tangshan station (2003—2019)

表4 5种时间尺度下

LSTM预测模型的MAE、RMSE、 R^2 值

Tab. 4 MAE, RMSE and R^2 values of LSTM prediction model under 5 time scales

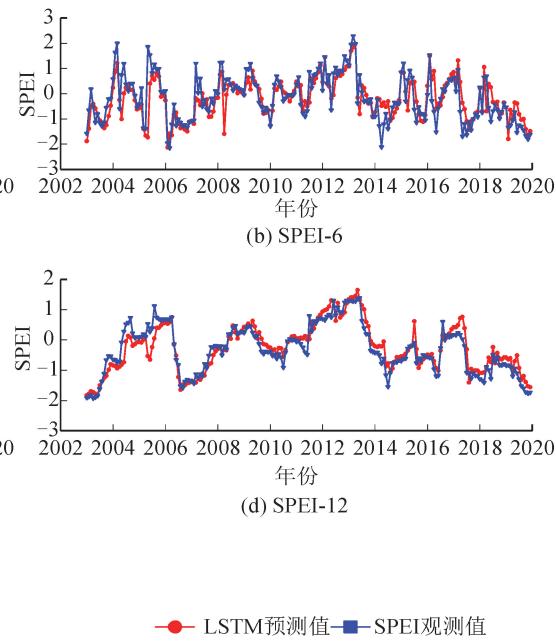
时间尺度	MAE	RMSE	R^2
3	0.473	0.627	0.604
6	0.344	0.490	0.760
9	0.275	0.397	0.846
12	0.212	0.299	0.912
24	0.197	0.260	0.935

由表4可知,LSTM模型在3个月时间尺度下预测精度最低($MAE=0.473$, $RMSE=0.627$, $R^2=0.604$),在24个月时间尺度下预测精度最高($MAE=0.197$, $RMSE=0.260$, $R^2=0.935$),且随着SPEI时间尺度的增加,其预测精度越高。

2.3 LSTM空间分布预测

不同时间尺度的SPEI可以表征不同类型的干旱,一般3~6个月尺度的SPEI用于监测农业干

旱。随着SPEI时间尺度的增加,LSTM模型预测精度变高的趋势。为了进一步验证这一趋势,本文分别统计了22个气象站点在多个时间尺度下的模型精度评价指标的平均值,其结果见表4。



旱^[15]。因京津冀的农作物生存期大多数都在3~6个月且该地区干旱频发,一年四季都有不同程度的干旱。

基于此,本文对比分析了京津冀2019年LSTM模型预测的季节和年时间尺度的SPEI的空间分布与实际值,结果见图7。

由图7(b)和图7(f)可知,京津冀的春季和秋季旱情分布类似,SPEI低值主要分布在研究区的东南部地区。由图7(d)可知,夏季旱情主要分布在北部的承德、北京和唐山以及南部的衡水、邢台和邯郸等地。由图7(h)可知,冬季旱情主要分布在京津冀的东部,其余地区处于无旱状态。而年尺度旱情与季节尺度旱情分布较为不同。由图7(j)可知,在年时间尺度上,京津冀干旱主要发生在该区域的中南部和东北部地区,其中旱情在唐山、衡水、邢台和邯郸等东南部分地区较重,而在其他地区旱情较轻。并从图7(a)、图7(c)、图7(e)、图7(g)和图7(i)可以看出LSTM模型预测精度较高,其预测的旱情空间分布与实际旱情空间分布基本一致。

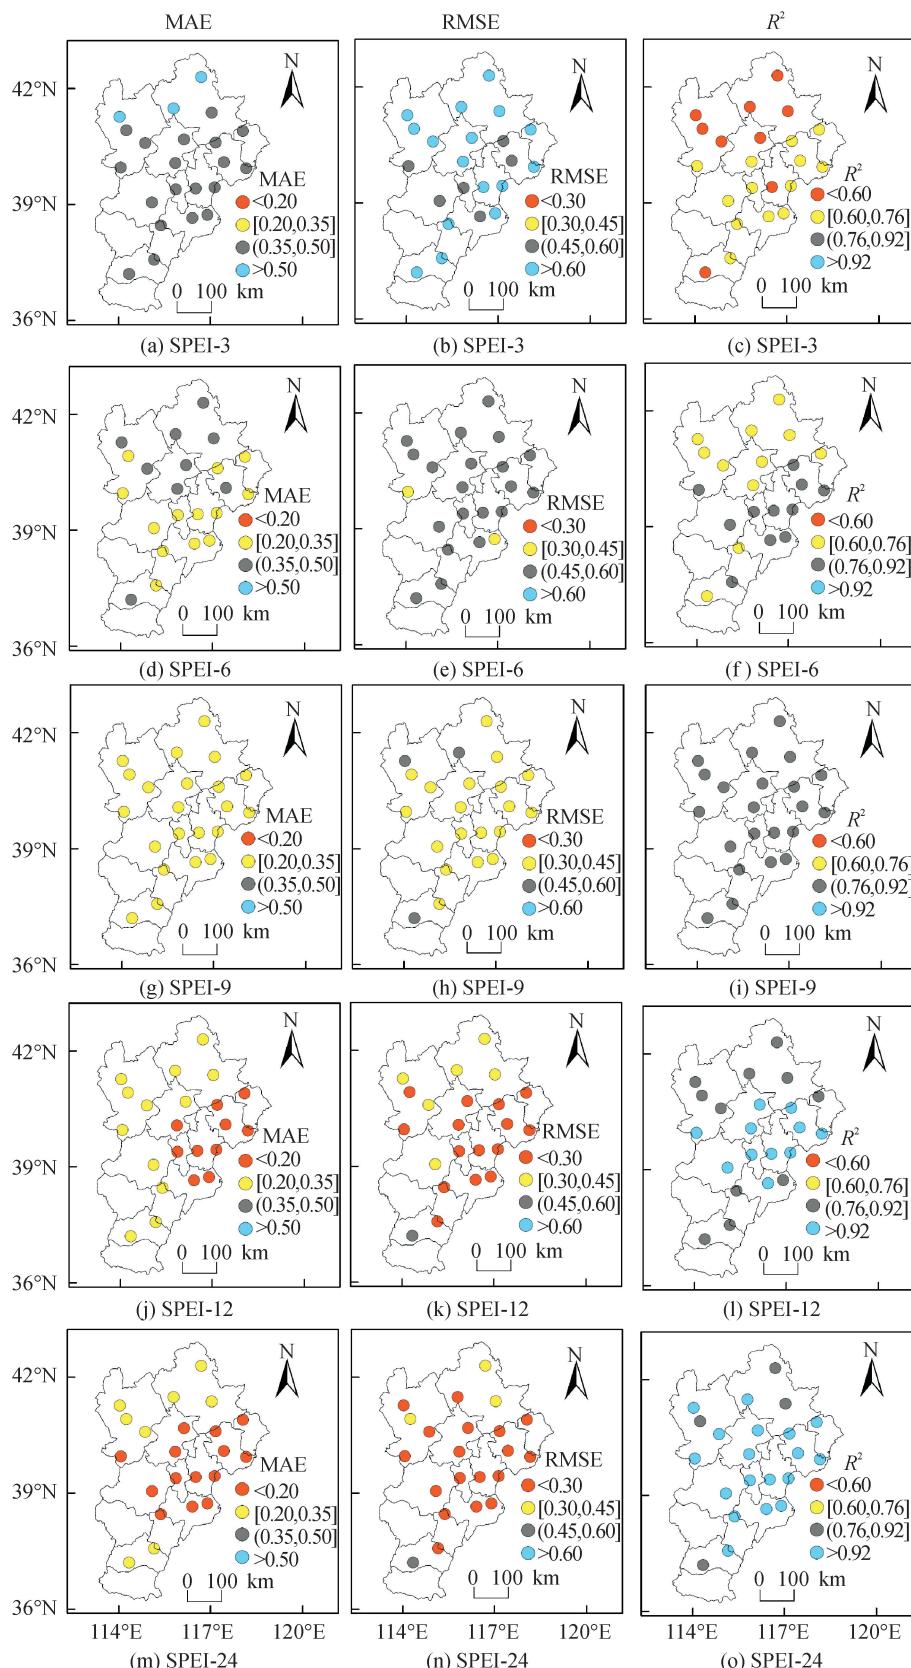


图 6 多时间尺度下的 LSTM 模型预测精度评定结果空间分布

Fig. 6 Spatial distribution of prediction accuracy evaluation results of LSTM model under multi-time scales
注: 底图来自国家自然资源部标准地图服务网站, 审图号为 GS(2015)732, 底图无修改。

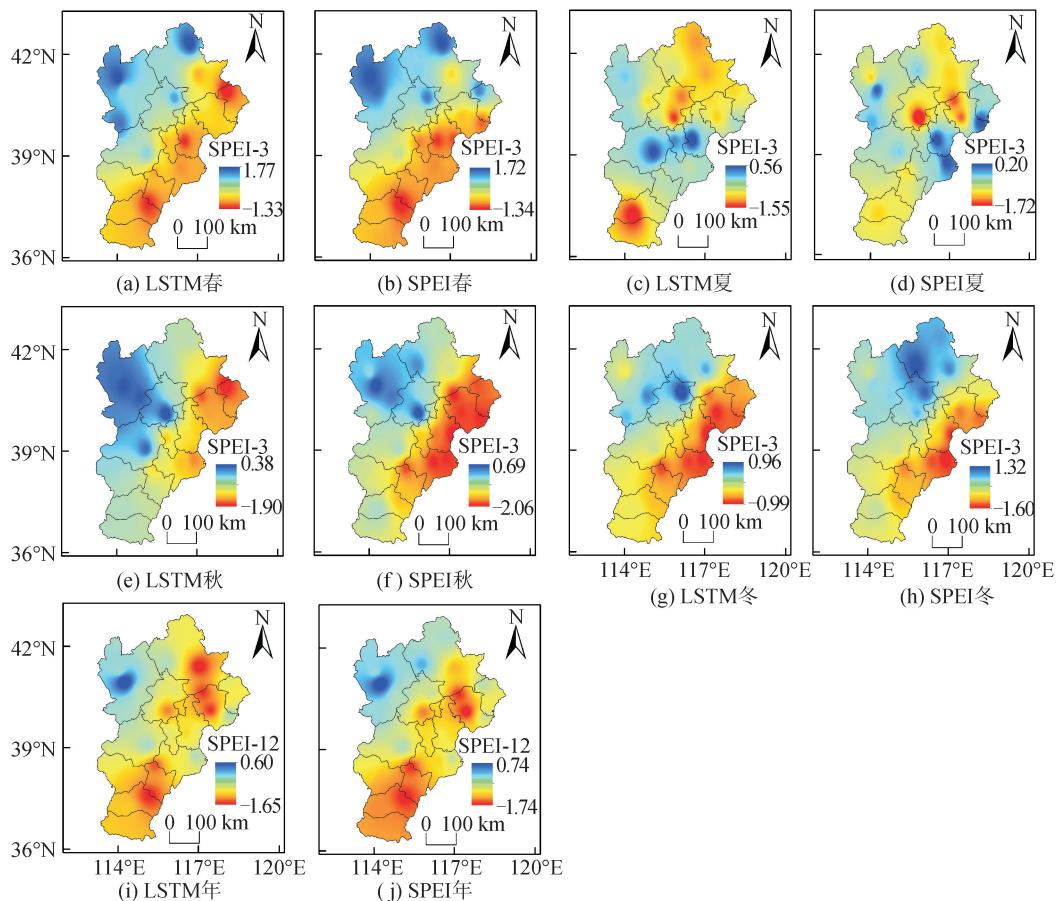


图 7 基于 LSTM 的 2019 年京津冀地区季尺度和年尺度干旱空间分布

Fig. 7 Spatial distribution of seasonal and annual drought in the Beijing-Tianjin-Hebei region in 2019 based on LSTM
注: 底图来自国家自然资源部标准地图服务网站,审图号为 GS(2015)732,底图无修改。

3 结论与讨论

3.1 结 论

基于 1961—2019 年京津冀气象站点的降水、气温、湿度、气压等多种气象因子,本文按站点构建 LSTM 模型对 3、6、9、12 和 24 个月多时间尺度的 SPEI 进行预测,并利用模型评价指标对 LSTM 预测模型进行精度评定,得到结论如下。

1) LSTM 模型对唐山站测试集(2003—2019 年)多时间尺度的 SPEI 进行预测,其预测值与实际 SPEI 值较为接近,其中 LSTM 模型对 3 个月时间尺度的 SPEI 预测精度最低,对 24 个月时间尺度的 SPEI 预测精度最高。

2) LSTM 模型在京津冀所有站点上对多时间尺度 SPEI 的总体预测精度较好,其 R^2 均在 0.503 以上,MAE 与 RMSE 分别均在 0.531 和 0.730 以下。其中在 3、12 和 24 个月时间尺度上,LSTM 模型预测精度最高的站点均为遵化站,而在 6 和 9 个月时间尺度上,LSTM 模型预测精度最高的站点分

别为蔚县和沧州站。并且对所有站点的模型评价指标在不同时间尺度上进行统计发现,LSTM 模型的预测精度随着 SPEI 时间尺度的增加而不断提高。

3) 由 LSTM 模型对京津冀 2019 年干旱空间分布预测的结果表明,LSTM 对季尺度和年尺度的 SPEI 干旱空间分布与实际的 SPEI 干旱空间分布基本一致,其中京津冀地区春季和秋季的旱情分布类似,且年尺度的干旱空间分布与季尺度有所不同。

3.2 讨 论

本文利用月降水量、气温、气压和相对湿度等多个气象因子,基于京津冀地区各气象站点构建 LSTM 预测模型对多时间尺度的 SPEI 进行预测的过程中,发现 LSTM 模型的预测精度与 SPEI 的时间尺度有一定的相关性,且随着 SPEI 时间尺度的增加而提高。而这一规律与张建海等^[16]和杨慧荣等^[10]分别利用 LSTM 模型和 ANN 模型对多时间尺度 SPI 和 SPEI 进行干旱预测研究中所得到的结论一致。原因可能是因为 LSTM 是 RNN 的变体,其在 RNN 内部加入保留前一时刻信息单元的模

块,往往在长时间序列预测中表现十分优秀^[35]。因此对于长时间尺度的 SPEI,LSTM 往往能够利用更多时间序列上的气象因子信息对其进行预测,从而得到更加精确的 SPEI 预测值。虽然不同于对单一变量的干旱预测研究,本文利用多要素气象因子构建 LSTM 模型对多时间尺度的 SPEI 进行干旱预测研究,并取得了较好的预测效果,但干旱的影响因子众多且作用机理复杂,不仅受到气象因子的影响,也会受到人为因素和地形等自然因素的影响^[36]。因此在后续研究中,应考虑到这些干旱影响因素并将其加入到干旱预测模型构建中以便对干旱更加准确地进行预测。

参考文献:

- [1] 高涛涛,殷淑燕,王水霞,等. 基于 SPEI 指数的秦岭南北地区干旱时空变化特征[J]. 干旱区地理,2018,41(4):761-770.
GAO Taotao, YIN Shuyan, WANG Shuxia, et al. Spatial and temporal variations of drought in northern and southern regions of Qinling Mountains based on standardized precipitation evapotranspiration index[J]. Arid Land Geography, 2018, 41(4): 761-770.
- [2] YAO Ning, LI Yi, LEI Tianjie, et al. Drought evolution, severity and trends in mainland China over 1961-2013[J]. Science of The Total Environment, 2018, 616/617: 73-89.
- [3] ZHAO Anzhou, ZHANG Anbing, CAO Sen, et al. Responses of vegetation productivity to multi-scale drought in Loess Plateau, China[J]. CATENA, 2018, 163: 165-171.
- [4] 翁白莎,严登华. 变化环境下中国干旱综合应对措施探讨[J]. 资源科学,2010,32(2):309-316.
WENG Baisha, YAN Denghua. Integrated strategies for dealing with drought in changing environment in China[J]. Resources Science, 2010, 32(2): 309-316.
- [5] 谢培,顾艳玲,张玉虎,等. 1961-2015 年新疆降水及干旱特征分析[J]. 干旱区地理,2017,40(2):332-339.
XIE Pei, GU Yanling, ZHANG Yuhu, et al. Precipitation and drought characteristics in Xinjiang during 1961-2015 [J]. Arid Land Geography, 2017, 40 (2): 332-329.
- [6] 张玉虎,向柳,孙庆,等. 贝叶斯框架的 Copula 季节水文干旱预报模型构建及应用[J]. 地理科学,2016,36(9): 1437-1444.
ZHANG Yuhu, XIANG Liu, SUN Qing, et al. Bayesian probabilistic forecasting of seasonal hydrological drought based on Copula function[J]. Scientia Geographica Sinica, 2016, 36(9): 1437-1444.
- [7] 吴晶,罗毅,李佳,等. CMIP5 模式对中国西北干旱区模拟能力评价[J]. 干旱区地理,2014,37(3): 499-508.
WU Jing, LUO Yi, LI Jia, et al. Evaluation of CMIP5 modes' s simulation ability in the northwest arid areas of China[J]. Arid Land Geography, 2014, 37(3): 499-508.
- [8] 沈国强,郑海峰,雷振锋. SPEI 指数在中国东北地区干旱研究中的适用性分析[J]. 生态学报,2017,37(11): 3787-3795.
SHEN Guoqiang, ZHENG Haifeng, LEI Zhenfeng. Applicability analysis of SPEI for drought research in Northeast China[J]. Acta Ecologica Sinica, 2017, 37 (11): 3787-3795.
- [9] 张菡,张喜亮,李金建,等. 基于 SPEI 的四川省盆地区季节性干旱时空变化特征分析[J]. 干旱地区农业研究,2018,36(5):242-250,256.
ZHANG Han, ZHANG Xiliang, LI Jinjian, et al. SPEI-based analysis of temporal and spatial variation characteristics for seasonal drought in Sichuan Basin [J]. Agricultural Research in The Arid Areas, 2018, 36(5): 242-250, 256.
- [10] 杨慧荣,张玉虎,崔恒建,等. ARIMA 和 ANN 模型的干旱预测适用性研究[J]. 干旱区地理,2018,41(5): 945-953.
YANG Huirong, ZHANG Yuhu, CUI Hengjian, et al. Applicability of ARIMA and ANN models for drought forecasting[J]. Arid Land Geography, 2018, 41(5): 945-953.
- [11] 王媛媛,张勃. 基于标准化降水指数的近 40a 陇东地区旱涝时空特征[J]. 自然资源学报,2012,27(12): 2135-2144.
WANG Yuanyuan, ZHANG Bo. Analysis of drought-flood spatial-temporal characteristics based on standarized precipitation index in east region of Gansu in recent 40 years [J]. Journal of Natural Resources, 2012, 27(12): 2135-2144.
- [12] 张岳军,郝智文,王雁,等. 基于 SPEI 和 SPI 指数的太原多尺度干旱特征与气候指数的关系[J]. 生态环境学报,2014,23(9):1418-1424.
ZHANG Yuejun, HAO Zhiwen, WANG Yan, et al. Multiscale characteristics of drought base on SPEI and SPI in association with climate index in Taiyuan[J]. Ecology and Environmental Sciences, 2014, 23 (9): 1418-1424.
- [13] 张露,朱仲元,席小康,等. 基于 SPEI 的锡林河流域干旱演化特征分析[J]. 干旱区研究,2020,37 (4): 819-829.
ZHANG Lu, ZHU Zhongyuan, XI Xiaokang, et al. Analysis of drought evolution in Xilin River Basin based on standarized precipitation evapotranspiration index [J]. Arid Zone Research, 2020, 37 (4): 819-829.
- [14] DRUMOND A, STOJANOVIC M, NIETO R, et al. Dry and wet climate periods over eastern south america: identification and characterization through the SPEI index[J]. Atmosphere, 2021, 12(2): 155.

- [15] 张建海,张棋,许德合,等. EBK 和 LSTM 模型在气象干旱时空预测中的应用[J]. 人民黄河,2020,42(8): 77-82.
- ZHANG Jianhai, ZHANG Qi, XU Dehe, et al. Temporal and spatial distribution prediction of meteorological drought based on EBK and LSTM model [J]. Yellow River, 2020, 42(8): 77-82.
- [16] 张建海,张棋,许德合,等. ARIMA-LSTM 组合模型在基于 SPI 干旱预测中的应用——以青海省为例[J]. 干旱区地理,2020,43(4):1004-1013.
- ZHANG Jianhai, ZHANG Qi, XU Dehe, et al. Application of a combined ARIMA-LSTM model based on SPI for the forecast of drought: a case study in Qinghai province[J]. Arid Land Geography, 2020, 43(4): 1004-1013.
- [17] 刘新,赵宁,郭金运,等. 基于 LSTM 神经网络的青藏高原月降水量预测[J]. 地球信息科学学报,2020,22(8):1617-1629.
- LIU Xin, ZHAO Ning, GUO Jinyun, et al. Prediction of monthly precipitation over the Tibetan Plateau based on LSTM neural network[J]. Journal of Geo-Information Science, 2020, 22(8): 1617-1629.
- [18] DIKSHIT A, PRADHAN B, HUETE A. An improved SPEI drought forecasting approach using the long short-term memory neural network[J]. Journal of Environmental Management, 2021, 283: 111979.
- GAO Shuai, HUANG Yuefei, ZHANG Shuo, et al. Short-term runoff prediction with GRU and LSTM networks without requiring time step optimization during sample generation [J]. Journal of Hydrology, 2020, 589: 125188.
- [20] 赵安周,王冬利,范倩倩,等. TRMM 数据在京津冀地区干旱监测适用性研究[J]. 水资源与水工程学报,2020,31(2):235-242.
- ZHAO Anzhou, WANG Dongli, FAN Qianqian, et al. Evaluating the applicability of TRMM data in monitoring drought events in Beijing-Tianjin-Hebei region [J]. Journal of Water Resources and Water Engineering, 2020, 31(2): 235-242.
- [21] 李双双,杨赛霓,刘宪锋. 面向非过程的多灾种时空网络建模:以京津冀地区干旱热浪耦合为例[J]. 地理研究,2017,36(8):1415-1427.
- LI Shuangshuang, YANG Saini, LIU Xianfeng. Spatiotemporal network modeling in concurrent heat waves and drought in Beijing-Tianjin-Hebei metropolitan region, China[J]. Geographical Research, 2017, 36(8): 1415-1427.
- [22] 焦毅蒙. 京津冀地区极端温度事件时空变化规律及城市化对其影响研究[D]. 北京:中国地质大学,2019.
- JIAO Yimeng. Study on the spatial and temporal variation of extreme temperature events in Beijing-Tianjin-Hebei region and the impact of urbanization on them [D]. Beijing: China University of Geosciences, 2019.
- [23] 王立丽,张安兵. 基于温度供水干旱指数的京津冀春旱监测及时空分布分析[J]. 测绘与空间地理信息,2021,44(4):72-75.
- WANG Lili, ZHANG Anbing. Spring drought monitoring in Beijing-Tianjin-Hebei based on temperature water supply drought index[J]. Geomatics & Spatial Information Technology, 2021, 44(4): 72-75.
- [24] 胡欣欣,张玉虎,向柳. 新疆阿克苏地区气象干旱特征研究[J]. 安徽农业科学,2015,43(35): 96-100,104.
- HU Xinxin, ZHANG Yuhu, XIANG Liu. The characteristics of meteorological drought in Aksu in Xinjiang [J]. Journal of Anhui Agricultural Sciences, 2015, 43(35): 96-100, 104.
- [25] 李伟光,侯美亭,陈汇林,等. 基于标准化降水蒸散指数的华南干旱趋势研究[J]. 自然灾害学报,2012,21(4):84-90.
- LI Weiguang, HOU Meiting, CHEN Huilin, et al. Study on drought trend in south China based on standardized precipitation evapotranspiration index [J]. Journal of Natural Disasters, 2012, 21(4): 84-90.
- [26] VICEBTE-SERRANO S M, BEGUERÍA S, LÓPEZ-MORENO J I. A multi-scalar drought index sensitive to global warming: the standardized precipitation evapotranspiration index[J]. Journal of Climate, 2010, 23(7): 1696-1718.
- [27] 中华人民共和国国家质量监督检验检疫总局,中国国家标准化管理委员会. 气象干旱等级:GB/T 20481—2006[S]. 北京:中国标准出版社,2006.
- [28] 刘珂,姜大膀. 基于两种潜在蒸散发算法的 SPEI 对中国干湿变化的分析[J]. 大气科学,2015,39(1):23-36.
- LIU Ke, JIANG Dabang. Analysis of dryness/wetness over China using standardized precipitation evapotranspiration index based on two evapotranspiration algorithms[J]. Chinese Journal of Atmospheric Sciences, 2015, 39(1): 23-36.
- [29] 王钧,李广,刘强. 基于 LSTM 神经网络模拟的陇中黄土高原沟壑区保护性耕作下土壤贮水量变化[J]. 中国生态农业学报(中英文),2019,27(8):1226-1237.
- WANG Jun, LI Guang, LIU Qiang, et al. Soil water storage under conservation tillage based on LSTM neural network simulation in the Loess Plateau Gully Region of central Gansu[J]. Chinese Journal of Eco-Agriculture, 2019, 27(8): 1226-1237.
- [30] 李广,黄包宝,BELLOTTI W,等. APSIM 模型在黄土丘陵沟壑区不同耕作措施中的适用性[J]. 2009, 29(5):2655-2663.
- LI Guang, HUANG Baobao, BELLOTTI W, et al. Adaptation research of APSIM model under different tillage systems in the Loess hill-gullied region[J]. Acta Ecologica Sinica, 2009, 29(5): 2655-2663.

(3):58-65.

HE Shaobo, SUN Kehui, WANG Huihai. Solution of the fractional-order chaotic system based on Adomian decomposition algorithm and its complexity analysis [J]. *Acta Physica Sinica*, 2014, 63(3): 58-65.

[15] 曹立伟, 梁占红, 高金峰. 互联电力系统的 Adomian 分解法求解及其混沌特性分析[J]. 电测与仪表, 2016, 53(21): 22-27.

CAO Liwei, LIANG Zhanhong, GAO Jinfeng. Solution of the interconnected power system based on Adomian decomposition method and its chaotic characteristic analysis[J]. *Electrical Measurement & Instrumentation*, 2016, 53(21): 22-27.

[16] 雷腾飞, 陈恒, 王艳玲, 等. 基于 Adomian 分解法的分数阶 Bao 混沌系统动力学分析与电路实现[J]. 数学的实践与认识, 2020, 50(14): 252-258.

LEI Tengfei, CHEN Heng, WANG Yanling et al. So-

lution analysis of the fractional-order Bao Chaotic system based on adomian decomposition and circuit implementation[J]. *Mathematics in Practice and Theory*, 2020, 50(14): 252-258.

[17] QIN Chuan, SUN Kehui, HE Shaobo. Characteristic analysis of fractional-order memristor-Based hypogenetic Jerk system and its DSP implementation[J]. *Electronics*, 2021, 10(7): 841.

[18] 吴周青. 基于 FPGA 的新型分数阶多翼混沌系统设计及其应用研究[D]. 重庆: 重庆邮电大学, 2019.

WU Zhouqing. Research on the design and application of a novel fractional multi-wing chaotic system based on FPGA[D]. Chongqing: Chongqing University of Posts and Telecommunications, 2019.

[19] 刘宗华. 混沌动力学基础及其应用[M]. 第6版. 北京: 高等教育出版社, 2006.

(责任编辑 王绪迪)

(上接第365页)

[31] 王鑫, 吴际, 刘超, 等. 基于 LSTM 循环神经网络的故障时间序列预测[J]. 北京航空航天大学学报, 2018, 44(4): 772-784.

WANG Xin, WU Ji, LIU Chao, et al. Exploring LSTM based recurrent neural network for failure time series prediction[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2018, 44(4): 772-784.

[32] 刘欣, 李佩娟, 盛云龙. 基于 Tensorflow 框架的生产线零件编号分类算法研究[J]. 南京工程学院学报(自然科学版), 2019, 17(4): 31-37.

LIU Xin, LI Peijuan, SHENG Yunlong. Research of part number classification algorithm of production line based on tensorflow framework[J]. *Journal of Nanjing Institute of Technology (Natural Science Edition)*, 2019, 17(4): 31-37.

[33] SHEN Xu, TIAN Xinmei, LIU Tongliang, et al. Continuous dropout [J]. *IEEE Transactions on Neural*

Networks and Learning Systems, 2017, 29(9): 3926-3937.

[34] KINGMA D, BA J. Adam: a method for stochastic optimization[OL]. arXiv, 2014. <https://arxiv.org/abs/1412.6980v8>.

[35] 高玉才, 付忠广, 谢玉存, 等. 基于 BP-LSTM 的旋转机械振动信号异常检测模型[J]. 煤矿机械, 2021, 42(8): 210-213.

GAO Yucai, FU Zhongguang, XIE Yucun, et al. Anomaly detection model of rotating machinery vibration signal based on BP-LSTM[J]. *Coal Mine Machinery*, 2021, 42(8): 210-213.

[36] HUANG Jinlong, ZHAI Jianqing, JIANG Tong, et al. Analysis of future drought characteristics in China using the regional climate model CCLM[J]. *Climate Dynamics*, 2018, 50(1): 507-525.

(责任编辑 王绪迪)