

基于BO-CNN-LSTM的锡林郭勒草原干旱预测模型

杜娟^{1*}, 董世杰¹, 贺云²

(1. 内蒙古财经大学统计与数学学院, 内蒙古 呼和浩特 010070; 2. 内蒙古农业大学水利与土木建筑工程学院, 内蒙古 呼和浩特 010018)

摘要:【目的】建立基于BO-CNN-LSTM耦合神经网络的干旱预测模型, 探索干旱预测的适用性。【方法】首先, 基于长短期记忆网络(LSTM)的记忆功能, 将其嵌入卷积神经网络(CNN)全连接层。其次, 为确定最优超参数, 将贝叶斯优化算法(BO)的概率代理模型和采集函数引入至LSTM。最后, 建立BO-CNN-LSTM耦合神经网络模型用以预测干旱状况。【结果】1) BO-CNN-LSTM预测精度随时间尺度的增大而提高, 对SPEI-12模拟精度最高, 且判定系数 R^2 均在98%以上; 2) 与LSTM模型SPEI-12的模拟结果进行比较, BO-CNN-LSTM表现出更高拟合精度。其中 R^2 相对提高值为[4.63%, 8.67%], MSE的数量级由 10^{-2} 降至 10^{-3} ; 3) 通过BO-CNN-LSTM预测2023年锡林郭勒草原干旱空间分布, 结果显示该区域整体呈干旱态势。其中东乌珠穆沁旗站点区域属于中旱, 其它区域均属于重旱。【结论】BO-CNN-LSTM具有较高的计算精度, 尤其适用于预测SPEI-12, 故可将其应用于年时间尺度干旱预测。

关键词: 干旱预测; 贝叶斯优化算法; 卷积神经网络; 长短期记忆网络; 锡林郭勒草原

中图分类号: SS812.5 **文献标志码:** A **文章编号:** 1009-5500(2024)04-0064-12

DOI: 10.13817/j.cnki.cyycp.2024.04.008



干旱是世界上最常见和最复杂的自然灾害之一, 它具有发生频率高、波及范围广、持续时间长等特点, 会对全球社会经济发展和农业生产带来巨大危害。据统计, 每年因干旱造成的全球经济损失高达60~80亿美元, 远超其他气象灾害造成的经济损失^[1-2]。与其他生态系统相比, 草原更容易受到干旱的影响^[3-4]。

草原生态系统约占全球陆地面积的26%^[5], 储存着陆地生态系统34%的碳, 在调节气候变化和全球碳循环中发挥着重要作用^[6-7]。由于干旱灾害的频繁发生和长期持续, 使得草原退化严重, 导致草原生态环境极度脆弱, 降低了草原应对气候变化和环境灾害的能力, 给农牧区生产和生活等方面造成严重的影响和损失, 成为影响草原农牧业可持续发展的主要因素之一^[8]。因此, 开展干旱相关研究对于维护社会稳定, 践行绿水青山就是金山银山理念, 推动生态保护和高质量发展具有重要意义。

目前, 国内外学者从不同方面对干旱展开研究。郭焘等^[9]基于MODIS数据, 通过土壤含水量对锡林郭勒草原干旱化程度进行了定量分析。刘梦鸽等^[10]对蒙古冰草(*Agropyron mongolicum*)生理生态特征展开研究, 以期该植被能为干旱草原生态系统结构和功能稳定发挥作用。Dhorde^[11]通过温度植被干燥指数研究了印度西部干旱的时空变化。迎春等^[12]采用相对

收稿日期: 2023-12-12; **修回日期:** 2024-07-02

基金资助: 内蒙古自治区高等学校科学研究项目(NJZY23053); 内蒙古自然科学基金(2023QN01006; 2023LHMS01012); 内蒙古财经大学自治区直属高校基本科研业务费项目(NCYWT23027); 一流学科科研专项(YLXKZX-NCD-010)

作者简介: 杜娟(1988-), 女, 山东泰安人, 博士, 讲师, 研究方向为草原干旱监测与风险评估研究。E-mail: djsd2007@126.com

*通信作者。E-mail: djsd2007@126.com

亏缺量指标分析了苏尼特草原过去 58 年干旱变化特点。马景钊等^[13]从时间和空间两个维度对锡林郭勒草原干旱情况进行评估,对比分析了 SPI 和 SPEI 二者的适用性。郭靖捷等^[14]通过测定土壤理化性质,探究了植物对半干旱风沙草原土壤的改良效应。Camarero 等^[15]揭示了干旱、气候和树木之间的关系。

以上研究主要聚焦于干旱的演变特征、成灾过程和驱动条件,揭示了干旱对生态系统的影响以及生态系统对干旱的响应,而关于如何监测干旱状况的研究较少。近年来,随着机器学习和深度学习理论的快速发展,学者们基于人工智能技术展开了构造干旱预测模型的研究,以期对干旱状况进行预测。模型评估干旱的优势在于其具有良好的非线性映射能力,能够充分挖掘数据的特征,对干旱进行模拟和预测的精度较高,且模型预测具有计算资源成本低、简便、经济和易于实现等优势^[16]。

针对干旱监测模型国内外学者展开了深入研究,常用的干旱预测模型有集合经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)、人工神经网络(Artificial Neural Networks, ANN)、支持向量机(Support Vector Machine, SVM)和长短时记忆神经网络(Long Short-Term Memory Model, LSTM)等^[17]。其中,由于在 LSTM 模型中加入了遗忘、输入和输出这三种门,能够分别控制细胞状态中所要忘记、更新和输出的信息,因此被广泛用于长时间序列的预测^[18-20]。刘新等^[21]、马筛艳等^[22]分别采用 LSTM 模型模拟青藏高原和咸阳地区的月降水量数据;胡小枫等^[23]针对京津冀地区构建 LSTM 模型对多时间尺度的 SPEI 进行模拟;国外学者 Dikshit 等^[24]利用 LSTM 模型模拟了澳大利亚新南威尔士州 SPEI,以上研究结果均显示 LSTM 模型具有较好的预测效果。综上所述,基于干旱预测模型进行单一变量或单一时间尺度干旱分析的研究较多,在多时间尺度上基于多个干旱变量因子情况的研究较少^[25]。LSTM 这类单一模型的缺点是在时间序列预测中容易出现局部最优,并且原始数据的平稳性对其影响较大^[26]。总体来看,干旱预测模型的研究正处于完善阶段,未形成准确、成熟以及具有普遍适用性的标准化模型。

草原是一个复杂的生态系统,开展草原干旱灾害

监测可为有效评估草原综合状况提供依据。其中,内蒙古锡林郭勒草原是中国北方及其周边地区的重要生态屏障和畜牧业生产基地,属于干旱、半干旱气候区,年降水量少且时空分布不均匀,蒸发量和干燥度大,极易形成干旱灾害,因此本文选取锡林郭勒草原作为研究区域。草原拥有庞大的数据资料,而神经网络作为一个复杂的黑箱系统,对数据的特征具有较强捕捉和挖掘能力,结合前述对已有干旱监测模型的研究分析,本文基于标准化降水蒸散发指数 SPEI(Standardized Precipitation Evapotranspiration Index, SPEI)^[27]表征干旱,采用 BO-CNN-LSTM 耦合神经网络^[28]作为干旱预测模型。该模型利用 CNN 的表征学习能力提炼出数据高阶特征,将输出的高维矩阵一维化并进行线性整合,同时发挥 LSTM 的记忆功能,通过 BO 优化算法的概率代理模型和采集函数计算模型超参数最优解,最终实现干旱预测模型的构建。文中选取锡林郭勒草原及其周边 13 个站点 1950—2022 年月平均降水量和气温数据,利用 BO-CNN-LSTM 耦合神经网络模型对各尺度 SPEI 进行模拟,从输出结果的精度探索模型在干旱预测中的适用性。

1 材料和方法

1.1 研究区域及数据来源

锡林郭勒草原是我国北方典型的干旱半干旱草原地区,也是我国三大天然草地之一,地处内蒙古自治区中部的锡林郭勒盟境内,草地资源十分丰富。锡林郭勒草原地处 43°02'~44°52' N, 115°13'~117°06' E, 总面积 $2.026 \times 10^5 \text{ km}^2$, 地势南高北低,自西南向东北缓缓倾斜,海拔 800~1 300 m,高低起伏较小,是一个以高平原为主体,兼有多种地貌单元构成的地区;属中温带干旱、半干旱大陆性气候,以雨少、风大、寒冷为主要气候特征,以干旱、风蚀、暴风雪、霜冻、冰雹、白灾(雪灾)和黑灾(因少雪或无雪造成牧区牲畜大量死亡的灾害)等为主要气象灾害,对草原畜牧业危害严重;年平均降水量 200~350 mm,总体呈西北至东南递增的态势;年平均气温 0~3℃,与年平均降水量在空间上呈相反分布;年蒸发量 1 500~2 700 mm,年平均相对湿度在 60% 以下^[29]。

文中气象数据来源于中国气象数据共享服务平

台(<http://data.cma.cn/>),包含了1950—2022年锡林郭勒盟及周边共13个气象观测站月均气温和月降水量资料。研究区域高程数据来源于地理空间数据云(<http://www.gscloud.cn/search>),行政区划数据来源于中华人民共和国民政部网站(<http://xzqh.mca.gov.cn/map>)。图1所示为锡林郭勒草原及其周边地区气象站点分布图。




图1 锡林郭勒草原及其周边地区气象站点分布图

Fig. 1 The distribution of meteorological stations in the Xilingol grassland and its surrounding areas

1.2 标准化降水蒸散发指数 SPEI

标准化降水蒸散发指数(SPEI)是由 Sergio M Vicente-Serrano 等^[27]在2010年首次提出,是用于定量评价干旱程度的指数之一。SPEI在SPI的基础上考虑温度变化对干旱评估的影响,同时具有多尺度特点,对分析和调查旱情具有十分重要的意义。具体计算过程如下:

(1)使用 Thornthwaite 方法^[30]计算逐月潜在蒸发量(Potential Evapotranspiration, PET)。

$$PET = 16K \left(\frac{10T}{I} \right)^m \quad (1)$$

式中:参数 T 是以摄氏度为单位的月平均气温, I 是由月平均气温推算出的12个月的热量指数之和, m 是依赖于 I 的常值系数, K 是由纬度和月序数计算出的修正系数。

(2)利用 PET 值计算各月份的水分盈亏 D_i 。

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

式中: P_i 是各月份降水量。

(3)计算在不同时间尺度上 D_i 值的聚合 $X_{i,j}^k$ 。

$$X_{i,j}^k = \sum_{l=13-k+j}^k D_{i-1,l} + \sum_{l=1}^j D_{i,l} \quad j < k \quad (3)$$

$$X_{i,j}^k = \sum_{l=j-k+l}^j D_{i-1,l} \quad j \geq k \quad (4)$$

(4)通过三参数的对数逻辑分布来标准化 D_i , 从而计算 SPEI。

log-logistic 分布的概率密度函数表示为

$$f(x) = \frac{\beta}{\alpha} \left(\frac{x-\gamma}{\alpha} \right)^{\beta-1} \left(1 + \left(\frac{x-\gamma}{\alpha} \right)^{\beta} \right)^{-2} \quad (5)$$

D_i 的概率分布函数为

$$F(x) = \left[1 + \left(\frac{\alpha}{x-\gamma} \right)^{\beta} \right]^{-1} \quad (6)$$

式中: α 为尺度参数, β 为形状参数, γ 为原始参数, 各参数均可通过 L-矩估计方法获取。

(5)标准化累积概率密度求得相应 SPEI 值。

$$P = 1 - F(X) \quad (7)$$

式中: P 代表超过水分盈亏值的概率。

当累积概率 $P \leq 0.5$ 时,

$$W = \sqrt{-2 \ln(P)} \quad (8)$$

当累积概率 $P > 0.5$ 时, P 取值为 $1-P$, 则

$$W = \sqrt{-2 \ln(1-P)} \quad (9)$$

则

$$SPEI = W - \frac{C_0 + C_1 W + C_2 W^2}{1 + d_1 W + d_2 W^2 + d_3 W^3} \quad (10)$$

式中: $C_0 = 2.515517$, $C_1 = 0.802853$, $C_2 = 0.010328$, $d_1 = 1.432788$, $d_2 = 0.189269$, $d_3 = 0.001308$ 。

国际上通用 SPEI 干旱等级划分标准^[31]如表1所示。

表1 干旱等级划分

Table 1 Classification of Drought Levels

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

1.3 基于 BO-CNN-LSTM 耦合神经网络的锡林郭勒草原干旱预测模型

1.3.1 卷积神经网络 卷积神经网络(Convolutional

Neural Network), 简称为 CNN, 最早由 Yann LeCun 提出, 目前在图像识别、文本分类等领域得到广泛应用。图 2 为 CNN 网络模型的结构, 它一般由输入层、卷积层、池化层、全连接层和输出层构成。




图 2 CNN 网络结构示意图

Fig. 2 Schematic diagram of CNN network structure

下式为卷积计算方法:

$$y(i) = f_c(y(i-1) \times W_i + b_c) \quad (11)$$

式中: f_c 为该卷积层激活函数; $y(i-1)$ 为第 i 个卷积层的输入; W_i 为该卷积层的权重; b_c 为该卷积层的偏置。

1.3.2 长短期记忆网络 长短期记忆网络 (Long Short-Term Memory), 简称为 LSTM。它包含输入门、遗忘门和输出门, 以及与隐藏状态形状相同的记忆细胞, 能够对信息完成筛选和保留, 更好地捕捉时间序列数据中的依赖关系, 使得卷积神经网络中梯度消失的问题在一定程度上得到了缓解^[32], 如图 3 所示为 LSTM 网络具体结构。




图 3 LSTM 网络结构图

Fig. 3 LSTM network structure diagram

在图 3 中, 细胞状态 C_{t-1} 、隐层状态 h_{t-1} 和 X_t 为 LSTM 在 t 时刻的输入, 细胞状态 C_t 和隐层状态 h_t 为两个输出, 其中 h_t 还作为 t 时刻的输出。

1.3.3 贝叶斯优化算法 贝叶斯优化算法 (Bayesian Optimization), 简称为 BO, 其数学原理是

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (13)$$

式中: A 和 B 都是随机事件; $P(A)$ 是事件 A 发生的概率, 称为先验概率; $P(B)$ 是事件 B 发生的概率; $P(B|A)$ 是事件 A 发生的情况下, 事件 B 发生的条件概率; $P(A|B)$ 为事件 B 发生的情况下, 事件 A 发生的条件概率, 称为后验概率。

1.3.4 构建 BO-CNN-LSTM 耦合神经网络模型 鉴于衡量草原干旱状况的气象数据是一个典型时间序列数据, 文中通过发挥 CNN 网络的特征识别功能、LSTM 网络的记忆功能, 并结合 BO 概率代理模型和采集函数的优势, 借助于 BO-CNN-LSTM 耦合神经网络模型 (以下简称 BO-CNN-LSTM 模型) 用以预测锡林郭勒草原的干旱状况。下面具体介绍 BO-CNN-LSTM 模型的建模过程。

CNN 网络的核心是卷积层, 在模型训练过程中相当于一个滤波器, 负责提取输入数据的特征信息, 降低输入矩阵的规模。在卷积过程中, 通过 CNN 网络独有的稀疏连接和权值共享机制, 加快了模型的训练过程。CNN 网络本质上是一种输入到输出的映射, 其池化层通过对卷积计算后的数据进一步提炼, 降低输入矩阵的复杂性, 并将结果信息传递给全连接层进行加权计算, 将输出的高维矩阵一维化并进行线性整合。

CNN 网络相较于传统神经网络拥有参数共享和局部连接两大优势, 使得网络需要训练的参数大大减少且不会降低准确率。CNN 网络最大的优点在于特征检测, 但是该网络不具备记忆功能, 且全连接模式过于冗余且低效。鉴于 LSTM 网络的记忆功能, 众多研究者考虑到将 CNN 与 LSTM 网络结合使用^[33-34]。CNN 网络通过对输入的子序列进行解释, 然后将这些子序列一并提供给 LSTM 网络, LSTM 网络中细胞状态 C_{t-1} 的信息一直在上传递, t 时刻的隐层状态 h_t 与输入 X_t 会对 C_t 进行适当修改, 然后再传递至下一时刻。另外, C_{t-1} 还会参与 t 时刻输出 h_t 的计算, 最后隐层状态 h_{t-1} 的信息通过 LSTM “门” 结构修改细胞的状态, 并参与输出的计算。

在应用 LSTM 网络时, 存在一批超参数值需预先定义, 无法由训练数据驱动调整并获取的问题。确定超参数通常使用的方法是穷举搜索法, 但是会存在模型预测结果过度依赖于经验、须耗费大量时间、搜索

效率较低及陷入局部最优等弊端。因此考虑采用BO算法寻找超参数最优解。

BO算法的核心是概率代理模型和采集函数。代理模型以已有的采样数据为基础,对被代理的函数进行拟合,使计算量显著减少。该算法采用高斯过程作为概率代理模型,并估算出后验概率分布的均值 $\mu(x)$ 和方差 $\sigma^2(x)$ 。对目标函数进行如下建模

$$f(x) = N(\mu(x), \sigma^2(x)) \quad (14)$$

式中: N 为高斯分布。

BO算法首先通过观测先验概率 $P(A)$ 抽象出数据的分布机制 $P(B|A)$,然后根据更新的数据 $P(B)$ 获得含有更多信息的后验分布 $P(A|B)$,再利用式(13)的目标函数估计得出分布范围,最后通过采集函数在不确定性大以及期望值较高的区域寻找解。整个过程不断重复直到预测值之间的差异和最优值小于阈值,进而得到神经网络最优超参数设置。

图4即为BO-CNN-LSTM模型结构示意图,该模型主要分为两个部分,前半部分是CNN网络,主要负责提取气象资料的特征信息。后半部分是LSTM预测模型,主要负责根据提取到的特征信息对SPEI进行预测并输出。整个预测模型的训练步骤如下:

(1) 将 m 个特征数据组成1行 m 列矩阵,将每个时间序列样本构造为时间分布层,在不打破动态时序关系的前提下进行CNN深度特征提取。

(2) 通过CNN卷积及池化等操作融合多尺度特征,去除干扰和噪声信息,随后将处理后的时间序列输入到LSTM层;将BO算法输入到LSTM层对网络超参数进行优化。

(3) 在迭代过程中计算每个单元的输出值和误差项,不断更新模型参数直到误差收敛或迭代次数到最大值。

(4) 利用已划分好的测试集数据,对模型进行性能评估,以验证模型的预测结果。




图4 BO-CNN-LSTM结构示意图

Figure 4 Schematic diagram of BO-CNN-LSTM structure

1.4 准备工作

本试验设备为具有Intel Core i5-1035G1 1.00GHz处理器、16GB内存的电脑,使用MATLAB软件编程实现具体算法。

获取1950—2022年锡林郭勒草原及周边13个站点月平均气温和月平均降水量气象数据集,并将其作为网络输入,SPEI数据集作为网络输出。将数据集按7:3划分为训练数据集和测试数据集,即1950—2007年数据作为训练数据集,2008—2022年数据作为测试数据集。对数据进行归一化处理,这是保证训练效果极其重要的步骤,它可以大大提高神经网络寻找最优解的训练速度,本文通过最小—最大归一化方法将输入值控制在0~1之间。

基于贝叶斯优化算法对LSTM网络超参数进行优化,通过对目标函数进行迭代评估,返回目标函数中产生最小损失的超参数组合。经过多次实验,本文模型参数设置如下:LSTM网络层数为1;LSTM层神经元数量为16;舍弃神经元概率为0.3;迭代次数为500; L_2 正则化参数为 1×10^{-4} ;学习率为0.003;误差函数为MSE。

1.5 模型评价指标

选取统计量判决系数(R^2)和均方误差(Mean Square Error, MSE)作为模型的评价指标,用以验证所构建网络的有效性。其中 R^2 越大,说明拟合效果越好,最大值为1;MSE代表误差平方的期望值,MSE越小,说明预测结果越优。两个评价指标的计算公式如下:

$$R^2 = \frac{\sum_{i=1}^n (y_i - \bar{y})^2 - \sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (15)$$

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

式中: $\hat{y}_i$ 为预测值; y_i 为真实值; $\bar{y}$ 为 y_i 的平均值; n 为样本量。

2 结果与分析

2.1 BO-CNN-LSTM模型计算结果与分析

基于BO-CNN-LSTM模型对2008—2022年锡林郭勒草原各站点3个月、6个月及12个月时间尺

度 SPEI 序列(SPEI-3、SPEI-6 及 SPEI-12)建模,以研究区域中锡林浩特、西乌珠穆沁旗和二连浩特 3 个站点为例,计算结果如表 2。从表中可以看出,BO-CNN-LSTM 模型对 SPEI-12 模拟精度最高,其中西乌珠穆沁旗站点判定系数 R^2 高达 99.755%,均方误差 MSE 仅为 0.11%;该模型对 SPEI-3 和 SPEI-6 模拟精度较低,对 SPEI-3 模拟精度最低。为直观展示 BO-CNN-LSTM 模型的模拟精度,图 5 分别给出该模型对 SPEI-3、SPEI-6 及 SPEI-12 的拟合情况。结果表明,随着时间尺度的增大,BO-CNN-LSTM 模型对 SPEI 拟合精度逐步提高。

表 2 BO-CNN-LSTM 模型的评价表现

Table 2 Evaluation index values of BO-CNN-LSTM model

站点	评价指标	SPEI-3	SPEI-6	SPEI-12
锡林浩特	R^2	00.771 27	00.842 88	00.993 42
	MSE	00.186 35	00.110 38	00.002 69
西乌珠穆沁旗	R^2	00.758 48	00.824 50	00.997 55
	MSE	00.228 52	00.133 59	00.001 1
二连浩特	R^2	00.740 69	00.803 55	00.989 92
	MSE	00.236 43	00.157 44	00.005 94




图 5 BO-CNN-LSTM 模型对各站点多尺度 SPEI 拟合图

Fig. 5 Fitted diagram of multi-scale SPEI values for each station using the BO-CNN-LSTM model

鉴于BO-CNN-LSTM模型对SPEI-12拟合效果最好,同样以西乌珠穆沁旗、锡林浩特和二连浩特3个站点为例,在图6中给出了模型的训练样本拟合图、测试样本误差图以及拟合效果图。结果表明,

模型对训练数据进行了较高精度的模拟,最高精度可达99.884%;测试数据拟合值的误差仅在 $[-0.2, 0.2]$ 之间,进一步说明模型对SPEI-12具有较高的拟合精度。




图6 训练样本拟合值图、测试样本误差及拟合效果图

Fig. 6 Training sample fitting diagram ,test sample error diagram ,and fitting effect diagram

2.2 BO-CNN-LSTM模型与LSTM模型结果对比

基于LSTM模型^[11]对锡林郭勒草原各站点SPEI-12序列进行建模,以研究区域中锡林浩特、西乌珠穆沁旗和二连浩特3个站点为例,输出模型评价指标如表3所示。结果表明,BO-CNN-LSTM模型计算所得判定系数 R^2 均高于LSTM模型,在3个站点中 R^2 相对提高最大值为8.30%,最小值为4.12%。对比各站点均方误差MSE可以发现,BO-CNN-LSTM模型计算所得MSE均小于LSTM模型。

2.3 基于BO-CNN-LSTM模型预测干旱空间分布

2020和2021年各站点SPEI-12实际值和模拟值

表3 LSTM模型的评价表现

Table 3 Evaluation index values of LSTM model			
站点	评价指标	SPEI-12	本文模型 R^2 相对提高值/%
锡林浩特	R^2	0.947 43	4.63
	MSE	0.030 97	
西乌珠穆沁旗	R^2	0.958 07	4.12
	MSE	0.019 62	
二连浩特	R^2	0.914 07	8.30
	MSE	0.050 63	

最大相对误差分别为7.96%和9.46%,最小分别为0.82%和0.73%,且2年各站点模拟干旱等级与实际

干旱等级均一致;2022 年最大相对误差绝对值为 50.80%,最小为 0.08%,除阿巴嘎旗站点模拟干旱等级与实际干旱等级不一致外,其它站点干旱等级一致(表 4)。

表 4 2020–2022 年锡林郭勒草原各站点 SPEI-12 实际值与预测值

Table 4 Actual and predicted values of SPEI-12 at various stations on the Xilingol grassland from 2020 to 2022

站点	2020			2021			2022		
	实际值	模拟值	E/%	实际值	模拟值	E/%	实际值	模拟值	E/%
锡林浩特	-1.574 23 (重旱)	-1.69960 (重旱)	7.96	-0.346 77 (无旱)	-0.322 99 (无旱)	6.86	-1.925 87 (重旱)	-1.928 72 (重旱)	0.15
那仁	-1.446 71 (中旱)	-1.50011 (中旱)	3.69	0.539 79 (无旱)	0.543 71 (无旱)	0.73	-1.669 23 (重旱)	-1.67 881 (重旱)	0.57
宝力格	-1.23 248 (中旱)	-1.22238 (中旱)	0.82	0.332 39 (无旱)	0.318 49 (无旱)	4.18	-1.302 39 (中旱)	-1.325 11 (中旱)	1.74
二连浩特	-1.398 37 (中旱)	-1.48462 (中旱)	6.17	-0.02 139 (无旱)	-0.021 72 (无旱)	1.54	-2.112 53 (特旱)	-2.239 80 (特旱)	6.02
东乌珠穆沁旗	-1.116 04 (中旱)	-1.05439 (中旱)	5.52	0.456 55 (无旱)	0.430 18 (无旱)	5.78	-1.302 39 (中旱)	-1.301 35 (中旱)	0.08
阿巴嘎旗	-1.642 86 (重旱)	-1.683 10 (重旱)	2.45	-0.093 41 (无旱)	-0.094 41 (无旱)	1.07	-1.77451 (重旱)	-0.872 99 (轻旱)	50.80
朱日和	-1.09342 (中旱)	-1.079 98 (中旱)	1.23	-1.070 56 (中旱)	-1.123 90 (中旱)	4.98	-2.04713 (特旱)	-2.152 52 (特旱)	5.15
多伦县	-2.166 10 (特旱)	-2.135 18 (特旱)	1.43	-0.130 37 (无旱)	-0.142 70 (无旱)	9.46	0.71941 (无旱)	0.708 48 (无旱)	1.52

2020 年和 2021 年 BO-CNN-LSTM 模型所得旱情空间分布与实际分布基本一致,模拟精度较高;2022 年 BO-CNN-LSTM 模型模拟旱情空间分布与实际分布不完全一致,是由于在阿巴嘎旗站点处 BO-CNN-LSTM 模型模拟 SPEI-12 为 -0.872 99(轻旱),与实际 SPEI-12 为 -1.77451(重旱)不一致,但其它区域旱情情况基本一致。另外,2020 年锡

林郭勒草原整体属于干旱状况,其中多伦站点处的草原出现特旱,锡林浩特及阿巴嘎旗站点处的草原出现重旱,其它区域草原为中旱;2021 年锡林郭勒草原整体处于无旱状况,仅朱日和站点处的草原为轻旱;2022 年锡林郭勒草原整体属于干旱状况,仅有多伦县站点处的草原无旱,二连浩特和朱日和站点处的草原为特旱(图 7–8)。




图 7 2020–2022 年锡林郭勒草原 12 个月时间尺度实际干旱空间分布

Fig. 7 Actual spatial distribution of drought in the Xilingol grassland under the 12-month scale from 2020 to 2022

以研究区域中锡林浩特、西乌珠穆沁旗和二连浩特 3 个站点为例,预测结果如表 5 所示,干旱空间分布如图 9 所示。结果显示 2023 年在 12 个月时间尺度下锡林郭勒草原整体呈干旱态势,在东乌珠沁旗站点处的草原及周边区域为中旱,其它区域为重旱。

3 讨论

采用 BO-CNN-LSTM 模型对各站点 3、6 和 12 个月时间尺度 SPEI 进行模拟,结果显示该模型对 3 个月时间尺度 SPEI 拟合精度最低,对 12 个月时间尺度




图8 2020–2022年基于BO–CNN–LSTM的锡林郭勒草原12个月时间尺度模拟干旱空间分布

Fig. 8 Simulated Spatial distribution of drought in the Xilingol grassland under the 12-month scale based on the BO–CNN–LSTM model from 2020 to 2022

表5 2023年锡林郭勒草原12个月时间尺度SPEI预测值
Table 5 Predicted values of SPEI-12 in the Xilingol grassland in 2023

站点	预测值	干旱等级
锡林浩特	−1.398 65	中旱
乌珠穆沁旗	−1.878 23	重旱
二连浩特	−1.885 08	重旱




图9 2023年锡林郭勒草原12个月时间尺度干旱空间分布预测图

Fig. 9 Prediction of drought spatial distribution in the Xilingol grassland under the 12-month scale in 2023

SPEI拟合精度最高,即BO–CNN–LSTM模型的拟合精度会随着时间尺度的增加而提高。这一规律与杨慧荣等^[23,35]分别利用ANN及LSTM模型对多时间尺度SPEI进行干旱预测所得结论一致。该规律形成的原因主要有两方面:一是当时间尺度增大时,SPEI对降水和温度的敏感性减弱,曲线更平滑,模型预测更准确^[36–37];二是BO–CNN–LSTM模型中LSTM为RNN的变体,其在RNN内部加入保留前一时刻信息单元的模块^[38],使得LSTM能够利用更多时间序列上的气象信息,进而使得BO–CNN–LSTM模型对长时间尺度SPEI预测精度更高。

通过本研究结果发现,BO–CNN–LSTM模型具有更高的拟合精度,而单一模型的预测精度相对较低。这一结论与丁严等人采用LSTM单一模型对新疆进行干旱预测得到的结果一致^[26]。笔者认为是由于LSTM这类单一模型存在不能有效提取数据特征、网络容易出现局部最优和超参数需人为确定的问题,进而导致其计算精度相对较低。而BO–CNN–LSTM模型的优势是通过CNN^[39]提取出气象数据的特征,输入至LSTM模型进行运算,且结合BO算法中概率代理模型和采集函数^[40],克服了LSTM单一模型的弊端,从而使其计算精度更高。

BO–CNN–LSTM模型的优点是可以自动搜索和提取输入数据的特征,泛化能力强,适合分析时间序列的大型数据和高维数据,并且当增加数据时,易于更新模型。BO–CNN–LSTM模型的局限性为适用于长时间尺度下干旱预测,对于短时间尺度下干旱预测的精度较低。在今后的工作中应考虑模型输入的复杂性和多样性,因为干旱的产生不仅会受到气象因素的影响,也会受到人为因素和地形等自然因素的影响^[41],进而对干旱进行更加全面地预测。BO–CNN–LSTM模型的预测结果可与农牧业受灾面积、受灾损失等统计数据结合做关联分析,用于评估干旱事件对农牧业生产的影响。还可将BO–CNN–LSTM模型推广应用于径流预测^[42–43]、电力负荷预测^[44]、焚烧炉烟气浓度预测^[45]及空气质量指数预测^[46]等领域,为相关决策提供依据及参考。

4 结论

BO–CNN–LSTM模型可有效挖掘气象数据的

特征,自适应地进行超参数寻优,具有较强的泛化能力。通过BO-CNN-LSTM模型计算锡林郭勒草原多时间尺度SPEI,结果显示该模型对12个月时间尺度SPEI模拟精度最高;与LSTM单一模型计算结果比较,该模型具有更高的拟合精度。

参考文献:

- [1] 薛天翼,白建军. 基于TVDI和气象数据的陕西省春季旱情时空分析[J]. 水土保持研究,2017,24(4):240—246.
- [2] 张巧凤,刘桂香,于红博,等. 锡林郭勒草原土壤含水量遥感反演模型及干旱监测[J]. 草业学报,2017,26(11):1—11.
- [3] Raich J W, Tufekciogul A. Vegetation and soil respiration: correlations and controls [J]. Biogeochemistry, 2000, 48(1):71—90.
- [4] Wang H, Ni J, Prentice I C. Sensitivity of potential natural vegetation in China to projected changes in temperature, precipitation and atmospheric CO₂ [J]. Regional Environmental Change, 2011, 11(3):715—727.
- [5] Yang Y, Wang Z, Li J, *et al.* Assessing the spatiotemporal dynamic of global grassland carbon use efficiency in response to climate change from 2000 to 2013 [J]. Acta Oecologica—International Journal of Ecology, 2017, 81:22—31.
- [6] 方精云,朴世龙,赵淑清. CO₂失汇与北半球中高纬度陆地生态系统的碳汇[J]. 植物生态学报,2001,25(5):594—602.
- [7] Piao S L, Fang J Y, Ciais P, *et al.* The carbon balance of terrestrial ecosystems in China [J]. Nature, 2009, 458(7241):1009—1013.
- [8] 张巧凤,刘桂香. 锡林郭勒草原干旱灾害监测与风险评估研究[M]. 北京:中国农业科学技术出版社,2018.
- [9] 郭焘,于红博,马梓策,等. 基于MODIS的土壤含水量时空变化及干旱化程度风险[J]. 水土保持研究,2019,26(4):185—189.
- [10] 刘梦鸽,史佳梅,许冬梅,等. 异质生境条件下荒漠草原蒙古冰草生理生态特征的研究[J]. 草原与草坪,2023,43(6):94—100.
- [11] Dhorde A G, Patel N R. Spatio-temporal variation in terminal drought over western India using dryness index derived from long-term MODIS data [J]. Ecological Informatics, 2016, 32:28—38.
- [12] 迎春,艳萍,闫默茹. 1961年—2018年苏尼特草原干旱变化特征及危害[J]. 内蒙古科技与经济,2022,(17):83—85.
- [13] 马景钊,郝璐. 基于SPI和SPEI指数的锡林郭勒草原干旱时空变化特征[J]. 草业科学,2021,38(12):2327—2339.
- [14] 郭靖捷,任晓萌,蒙仲举,等. 半干旱风沙草原区盐湖植物防护体系土壤理化性状特征[J]. 中国农业科技导报,2024,26(1):182—192.
- [15] Camarero J J, Hevia A. Links between climate, drought and minimum wood density in conifers [J]. IAWA Journal, 2020, 41(2):236—255.
- [16] 潘海婷,莫慧偲,张琴,等. 基于NARX神经网络的湖南省空气质量预报效果评估研究[J]. 环境科学与管理,2022,47(9):170—174.
- [17] 张建海,张棋,许德合,等. EBK和LSTM模型气象干旱时空预测中的应用[J]. 人民黄河,2020,42(8):77—82.
- [18] 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.
- [19] Dikshit A, Pradhan B, Alamri A M. Long lead time drought forecasting using lagged climate variables and a stacked long short-term memory model [J]. Science of The Total Environment, 2021, 755(2):142638.
- [20] 李艳玲,巩雅杰. 基于驱动分析的LSTM干旱预测模型研究[J]. 数学的实践与认识,2022,52(5):92—102.
- [21] 刘新,赵宁,郭金运,等. 基于LSTM神经网络的青藏高原原月降水量预测[J]. 地球信息科学学报,2020,22(8):1617—1629.
- [22] 马筛艳,王薇,裴莉莉,等. 基于LSTM降水量预测的咸阳“旱腰带”地区干旱趋势分析[J]. 安徽农业科学,2023,51(13):192—197.
- [23] 胡小枫,赵安周,相恺政. LSTM模型在京津冀干旱预测应用中的研究[J]. 西安理工大学学报. 2022,38(3):356—365.
- [24] 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.
- [25] Gao S, Huang Y F, Zhang S, *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.
- [26] 丁严,许德合,曹连海,等. 基于CEEMD的LSTM和

- ARIMA 模型干旱预测适用性研究—以新疆为例[J]. 2022, 39(3): 734—744.
- [27] Vicente—Serrano S M, Begueria S, LoPez—Moreno J I. A multiscalar drought index sensitive to global warming: the standardized precipitation evapotranspiration index [J]. Journal of Climate, 2010, 23(7): 1696—1718.
- [28] 周军超, 刘乙翰, 陈奥, 等. 基于BO—CNN—LSTM的轨道车辆车体横向振动状态识别[J/OL]. 铁道科学与工程学报, 2024, <https://doi.org/10.19713/j.cnki.43-1423/u.T20231987>.
- [29] 杭玉玲, 包刚, 包玉海, 等. 2000—2010年锡林郭勒草原植被覆盖时空变化格局及其气候响应[J]. 草地学报, 2014, 22(6): 1194—1204.
- [30] Thornwaite C W. An approach toward a rational classification of climate[J]. The Geographical Review, 1948, 38(1): 55—94.
- [31] 中华人民共和国国家质量监督检验检疫总局. 气象干旱等级: GB/T 20481—2006[S]. 北京: 中国标准出版社, 2006: 1—21.
- [32] Hochreiter S, Schmidhuber J. Long short term memory [J]. Neural computation, 1997, 9(8): 1735—1780.
- [33] 刘云帆, 林亮行, 马国政, 等. 基于CNN和LSTM的航天用涂层型自润滑关节轴承寿命预测及可靠性评估[J]. 航天器环境工程, 2023, 40(5): 531—540.
- [34] 朱宗玖, 赵艺伟. 基于SSA—CNN—LSTM模型的空气质量指标预测[J]. 长春大学学报, 2023, 33(8): 1—7.
- [35] 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.
- [36] Mokhtarzad M, Eskandari F, Jamshidi V N, et al. Drought forecasting by ANN, ANFIS, and SVM and comparison of the models[J]. Environmental Earth Sciences, 2017, 76(21): 1—10.
- [37] 赵国羊, 涂新军, 王天, 等. 基于人工神经网络和支持向量回归机的干旱预测模型[J]. 人民珠江, 2021, 42(4): 1—9.
- [38] 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.
- [39] 戴永东, 金扬, 戴雨凡等. 航拍绝缘子图像缺陷智能识别算法研究[J]. 计算机科学. 2024, 51(S1): 530—534.
- [40] 赵军, 黄文静, 张恩韬等. 基于贝叶斯算法的自升式平台桩靴基础砂—黏地层峰值阻力预测[J]. 中国海上油气. 2024, 36(2): 216—224.
- [41] 谢岷, 高聚林, 孙继颖, 等. 基于SPEI指数的内蒙古多时空尺度干旱特征分析[J]. 灌溉排水学报, 2022, 41(6): 140—146.
- [42] 徐冬梅, 王逸阳, 王文川. 基于贝叶斯优化算法的长短期记忆神经网络模型年径流预测[J]. 水电能源科学, 2022, 40(12): 42—46.
- [43] 张梦凡, 丁兵兵, 贾国栋等. 基于TCN—BiLSTM与LSTM模型对比预测北洛河径流[J]. 2024, 46(4): 141—148.
- [44] 李琦, 许素安. 基于GSABO—BP和Bootstrap的电力负荷区间预测[J]. 现代电子技术, 2024, 47(10): 28—33.
- [45] 杨文玉, 张树才, 张卫华等. 基于ADPSO—FNN算法的催化再生烟气二氧化硫预测方法卢薇[J]. 安全与环境学报, 2023, 23(11): 4217—4135.
- [46] 张天娇, 海涛, 王钧, 等. 基于IPWAN和AQI指数预测的空气质量监测系统[J]. 科学技术与工程, 2024, 24(15): 6558—6566.

Drought prediction model for the Xilingol grassland based on BO—CNN—LSTM

DU Juan^{1*}, DONG Shu-jie¹, HE Yun²

(1. College of Statistics and Mathematics, Inner Mongolia University of Finance and Economics, Hohhot 010070, China; 2. College of Water Resources and Civil Engineering, Inner Mongolia Agricultural University, Hohhot 010018, China)

Abstract: [Objective] Reliable and effective monitoring can mitigate the impact of drought disasters on socio—

economic development and natural ecosystems. This study adopted the BO—CNN—LSTM coupled neural network as adrought prediction model. 【Method】 First, the memory function of long short—term memory (LSTM) was integrated into the fully connected layer of the convolutional neural network (CNN). Second, to determine the optimal hyperparameters for LSTM, the probability surrogate model and acquisition function from the Bayesian optimization (BO) algorithm were introduced. Finally, a BO—CNN—LSTM coupled neural network model was constructed to predict the drought conditions in the Xilingol grassland. 【Result】 (1) The prediction accuracy of the BO—CNN—LSTM model increased with the time scale, with the highest prediction accuracy observed under the 12—month scale for the Standardized Precipitation—Evapotranspiration Index (SPEI). The determination coefficient R^2 of SPEI—12 for each site exceeded 98%. (2) Compared to the simulation results of the LSTM model for SPEI—12, the proposed model exhibited higher fitting accuracy, showing a relative improvement in R^2 of [4.63%, 8.67%]. The order of magnitude of mean squared error (MSE) at each site had decreased from 10^{-2} to 10^{-3} . (3) Using the model to predict the spatial distribution of drought in the Xilingol grassland for 2023, indicated that the region as a whole was experiencing drought. Especially, the Dongwuzhumuqin Banner area was classified as experiencing moderate drought, while other areas were classified as severe drought. 【Conclusion】 The results demonstrate that the BO—CNN—LSTM model has high computational accuracy, making it particularly suitable for predicting SPEI—12. Therefore, the methods in this study can be effectively applied to drought prediction on an annual time scale.

Key words: drought prediction; Bayesian optimization algorithm; convolutional neural networks; long short—term memory network; Xilingol grassland

(责任编辑 康宇坤)