

引用格式:

李亮亮, 张聪, 曹坤, 黎帅锋. 自适应进化模型下的土壤重金属含量预测[J]. 湖南农业大学学报(自然科学版), 2024, 50(2): 120–126.

LI L L, ZHANG C, CAO K, LI S F. Soil heavy metal content under adaptive evolution model[J]. Journal of Hunan Agricultural University(Natural Sciences), 2024, 50(2): 120–126.

投稿网址: <http://xb.hunau.edu.cn>



## 自适应进化模型下的土壤重金属含量预测

李亮亮<sup>1</sup>, 张聪<sup>2\*</sup>, 曹坤<sup>1</sup>, 黎帅锋<sup>3</sup>

(1.武汉轻工大学数学与计算机学院, 湖北 武汉 430023; 2.武汉轻工大学电气与电子工程学院, 湖北 武汉 430023; 3.汉口学院计算机科学与技术学院, 湖北 武汉 430212)

**摘要:** 针对 Elman 神经网络在土壤重金属含量预测时出现预测精度低、模型收敛速度慢等问题, 提出一种自适应进化模型(AEM)。该模型以 Elman 神经网络为基础, 运用贝叶斯正则化优化 Elman 神经网络的目标函数, 提高网络模型预测精度; 为解决网络模型收敛速度慢和易陷入局部极值等缺陷, 采用自适应灰狼算法(AGWA)对网络模型初始参数进行优化; 采用基于熵权距离的离群点检测法剔除数据中的离群点, 以降低离群点对预测结果的干扰。以武汉市农业科学院采集的农田土壤重金属含量数据进行预测试验, AEM 模型预测重金属含量的平均绝对误差和平均绝对百分比误差分别为 1.623 和 17.48%, 其决定系数比 Elman 的提高了 0.394。AEM、自调整反距离加权插值模型(SIDIM)、小波神经网络模型(CBSA-WNN)、双向门控循环神经网络模型(SBGRNN)及 Elman 神经网络模型等 5 种不同预测模型进行对比试验表明, AEM 模型在土壤重金属含量预测上具有更高的准确性。消融试验结果表明, 贝叶斯正则化优化、自适应灰狼算法优化和基于熵权距离的离群点检测的离群点数据剔除等 3 个改进点对于提升土壤重金属含量预测精度均有一定的贡献。

**关键词:** 土壤重金属; 自适应进化模型; 灰狼算法; Elman 神经网络; 数据预测

中图分类号: TP183; X833 文献标志码: A 文章编号: 1007-1032(2024)02-0120-07

## Soil heavy metal content under adaptive evolution model

LI Liangliang<sup>1</sup>, ZHANG Cong<sup>2\*</sup>, CAO Kun<sup>1</sup>, LI Shuifeng<sup>3</sup>

(1.School of Mathematics and Computer Science, Wuhan Polytechnic University, Wuhan, Hubei 430023, China; 2.School of Electrical and Electronic Engineering, Wuhan Polytechnic University, Wuhan, Hubei 430023, China; 3.School of Computer Science and Technology, Hankou University, Wuhan, Hubei 430212, China)

**Abstract:** Aiming to address the problem of low prediction accuracy and slow convergence speed of Elman neural networks in predicting soil heavy metal content, an adaptive evolutionary model was proposed in this study. This model was based on the Elman neural network and used Bayesian regularization to optimize the objective function of the Elman neural network, improving the prediction accuracy of the network model. To overcome the shortcomings of slow convergence speed and susceptibility to local extremum in network models, the Adaptive Gray Wolf algorithm(AGWA) was used to optimize the initial parameters of the network model. And an outlier detection method based on entropy weight distance was used to remove outliers from the data, in order to reduce the interference of outliers on the prediction results. The prediction experiment was conducted using data on heavy metal content in farmland soil collected by Wuhan Academy of Agricultural Sciences. The average absolute error and average absolute percentage error of AEM model for predicting heavy metal content were 1.623 and 17.48%, respectively. Compared with Elman's comparative model, the determination

收稿日期: 2023-01-28

修回日期: 2024-04-20

基金项目: 国家自然科学基金项目(61272278); 湖北省重大科技专项(2018ABA099); 湖北省自然科学基金项目(2015CFA061、2018CFB408、2020CFB761)

作者简介: 李亮亮(1995—), 男, 湖北襄阳人, 硕士研究生, 主要从事人工智能技术及其运用研究, 1071723789@qq.com; \*通信作者, 张聪, 博士, 教授, 主要从事多媒体信息处理及网络通信研究, hb\_wh\_zc@163.com

coefficient index improved by 0.394. After conducting comparative experiments with five different prediction models(AEM, Elman, SBGRNN, SIDIM, CBSA-WNN), it was found that the AEM model had the highest accuracy in predicting soil heavy metal content. The results of the ablation experiment indicated that the three improvement points(Bayesian regularization optimizing, AGWA optimizing, and removing outliers from the data by using an outlier detection method based on entropy weight distance) all contributed to improving the accuracy of predicting soil heavy metal content to varying degrees.

**Keywords:** soil heavy metal; adaptive evolution mode; Grey Wolf algorithm; Elman neural network; data prediction

随着工业化进程的不断加速,土壤重金属污染问题变得越来越严峻<sup>[1-2]</sup>,土壤中重金属不断积累,进而危害到人类身体健康<sup>[3]</sup>。测量土壤中重金属含量是治理土壤重金属污染问题的前提条件<sup>[4]</sup>。近年来,各种数据预测模型层出不穷<sup>[5]</sup>:李洋莹等<sup>[6]</sup>在 Elman 神经网络中引入布谷鸟搜索来提高制糖原材料采购预测精度;张俊杰<sup>[7]</sup>使用改进的 Q 网络对反距离加权插值法中的参数进行优化,提出一种自调整反距离加权插值模型(SIDIM),提高了土壤重金属含量的预测精度;曹文琪<sup>[8]</sup>使用改进的鸟群算法对小波神经网络进行优化,提出一种基于协同鸟群算法的小波神经网络模型(CBSA-WNN),避免了原网络训练时陷入局部极小值;林靖皓等<sup>[9]</sup>在长短期记忆网络(LSTM)中加入双向门控循环单元并引入自注意力机制,提出一种基于自注意力机制的双向门控循环神经网络模型(SBGRNN),提高了模型收敛速度。

Elman 神经网络的初始权值和阈值设置不当会大大降低网络模型的收敛速度和预测精度<sup>[10]</sup>。采用改进后的灰狼算法<sup>[11-13]</sup>优化 Elman 神经网络在土壤重金属含量预测领域的应用鲜见。基于以上考虑,笔者提出一种自适应进化模型(AEM),该网络模型先运用贝叶斯正则化对 Elman 网络模型的目标函数进行改进<sup>[14-15]</sup>,再采用自适应灰狼算法优化网络模型中的初始参数,并采用基于熵权距离的离群点检测法剔除数据中的离群点<sup>[16-17]</sup>,以期采用 AEM 提高土壤重金属含量预测的精准度。

## 1 模型的建立

### 1.1 基于贝叶斯正则化的 Elman 神经网络

传统 Elman 神经网络训练过程的目标是使训练模型输出的预测值与实际样本的观测值更为接近,其接近程度采用均方误差函数表示,二者越接近,得出的均方误差越小。添加“惩罚项”后的目标函数

更新为  $J_{\omega}$ 。 $J_{\omega}$  通过 2 个正则化参数  $q$  和  $p$  控制其他参数的大小。当  $J_{\omega}$  为最小值时,将其所对应的权值设为  $\omega_{\min}$ 。在点  $\omega_{\min}$  附近,以泰勒公式<sup>[18-20]</sup>将  $J_{\omega}$  展开,并忽略掉高次项。利用高斯-牛顿逼近法<sup>[21]</sup>对  $J_{\omega}$  在点  $\omega_{\min}$  的 Hessian 矩阵进行替换。有效权值个数设为  $\varphi$ ,  $\varphi$  表示在网络训练过程中有多少个参数在降低总误差函数上起作用。综上所述,采用贝叶斯正则化优化 Elman 神经网络的具体步骤为:①选定网络结构,初始化  $q$  和  $p$ , 设  $q=0$ ,  $p=2$ ;②调整权值大小,使得函数  $J_{\omega}$  下降,以达到最小值;③使用高斯-牛顿逼近法求出 Hessian 矩阵;④计算  $\varphi$ , 并重新计算  $q$  和  $p$ ;⑤重复步骤①~④,当误差小于等于 0.002 时终止迭代。

### 1.2 自适应灰狼算法

采用改进后的 Elman 神经网络预测土壤重金属含量时,其网络参数的随机初始化往往导致预测性不够稳定,可以使用灰狼算法对其网络参数进行优化。针对传统灰狼算法<sup>[22]</sup>本身存在的缺陷,笔者提出一种自适应灰狼算法(AGWA)<sup>[23]</sup>,该算法在原算法的基础上引入余弦收敛因子和中心扰动规则,以此提高灰狼算法的收敛速度。

#### 1.2.1 余弦收敛因子

在传统灰狼算法中参数  $\vec{A}$  和参数  $\vec{a}$  随着迭代次数  $t$  的增加而递减,这一过程影响着灰狼个体的移动速度和移动距离。实际上,灰狼个体的位置变化不一定总朝着捕食猎物的最优解方向。 $\vec{a}$  的线性降低有可能导致狼群在迭代过程中陷入局部最优解的情况。针对上述问题,采用余弦收敛因子代替线性下降的  $\vec{a}$ 。

$$\vec{a} = \cos\left(\pi \times \frac{i}{i_{\max}}\right) + 1 \quad (1)$$

式中:  $i$  代表当前迭代次数;  $i_{\max}$  代表总迭代次数。根据式(1)可知,在迭代前期,  $\vec{a}$  缓慢减小,参数  $\vec{A}$  可以获得较大值并维持在较长的迭代周期中,由

此灰狼群体可以搜索更大的范围以发现更多猎物；在迭代后期， $\bar{a}$ 的减小速度由中期的较大值逐渐降低，此时灰狼群体向最优解移动的速度也会减慢，由此可以通过减缓收敛速度以扩大搜索范围，避免狼群陷入局部最优解。

### 1.2.2 中心扰动规则

在传统灰狼算法迭代过程中，个体连续多次出现位置更新前后适应度值保持不变的情况，说明该个体陷入局部最优解。使用中心扰动规则可有效解决上述问题。中心扰动规则采用  $T$  值统计狼群个体出现位置更新前后适应度值保持不变或降低的次數， $T$  值初始为 0，当个体位置更新后适应度值出现增加的情况， $T$  值会重新初始化。中心扰动的概率( $p$ )会随着  $T$  值变化而改变。

$$p=1-\exp(-\frac{T}{10}) \tag{2}$$

由式(2)可知， $T$  值为 0 时， $p$  值也为 0，此时个体没有陷入局部最优，无需对其进行中心扰动；当  $T$  值增加时，个体陷入局部最优的概率也随之增加，因而有较大概率需对其进行中心扰动。

中心扰动规则主要以狼群中心点的位置( $D_{mean}$ )对个体位置进行干预。

$$D_{mean}=|C \times X_{mean}(t) + X(t)| \tag{3}$$

$$X(t+1)=|X_{mean}(t) - A \times D_{mean}| \tag{4}$$

式中： $t$  为当前迭代次数； $X(t)$  为当前迭代次数下某只狼的位置信息； $A$  和  $C$  分别代表  $[0, 2]$  之间的随机值； $X_{mean}(t)$  为当前迭代次数下狼群中心点的位置信息，将  $\alpha$  狼、 $\beta$  狼和  $\delta$  狼位置信息的平均值作为  $X_{mean}(t)$ 。 $X_{mean}(t)$  是通过  $\alpha$  狼、 $\beta$  狼和  $\delta$  狼的位置信息获得，因而当狼群个体陷入局部最优时， $X_{mean}(t)$  可以助其改变移动方向，以逃出局部最优，同时在迭代过程中帮助狼群发现全局最优解。

### 1.3 基于熵权距离的离群点检测

由于土壤重金属数据采样点分布较广，且人为采集存在操作不当的情况，采集的数据集中往往存在一些离群数据，会对预测结果造成影响。为解决上述问题，采用基于熵权距离的离群点检测法剔除数据集中的离群点。首先，采用改进的  $k$ -means 算法对原始数据集快速进行聚类<sup>[24]</sup>，在得到更新后的聚类簇  $C$  后，再采用基于熵权距离的方法来检测离群点数据<sup>[25]</sup>。聚类簇  $C=\{x_1, x_2, \dots, x_n\}$ ， $n$  为聚类簇

$C$  的大小。属性集  $A=\{A_1, A_2, \dots, A_d\}$ ，其中  $d$  为数据集的维度。

$$H(A_i)=-\sum_{x_j} P(x_j) \log_2 P(x_j) \tag{5}$$

式中： $H(A_i)$  为信息熵； $x_j \in S(A_i)$ ； $S(A_i)$  是属性  $A_i$  的取值集合； $P(x_j)$  是属性  $A_i$  下的第  $j$  个数据所占比重，在这里将其看作熵计算中用到的概率。当  $H(A_i) \geq \frac{\sum_i H(A_i)}{d}$  时，称属性  $A_i$  为离群属性；反之， $A_i$  则为符合条件的属性。

$$\theta_i = \begin{cases} q, & A_i \text{ 为离群属性} \\ 1, & A_i \text{ 为非离群属性} \end{cases} \tag{6}$$

式中： $\theta_i$  为各属性权重； $q > 1$ 。可以得出对象  $a$  和对象  $b$  的熵权距离计算公式。

$$\text{dist}(a,b)=\sqrt{\sum_{i=1}^d \theta_i (f_{A_i}(a)-f_{A_i}(b))^2} \tag{7}$$

式中  $f_{A_i}(a)$  和  $f_{A_i}(b)$  分别为对象  $a$  和对象  $b$  在属性  $A_i$  上的取值，属性  $A_i$  的权值为  $\theta_i(1, 2, \dots, d)$ 。由此可知，当离群属性的权值较大时，可以更好地表现出离群点的离群程度，以此来提高区别离群点和内部点的能力。当熵权距离大于设定的阈值时，可以输出离群点，并剔除离群点来达到更精确的数据拟合结果。

### 1.4 自适应进化模型

结合 AGWA、基于熵权距离的离群点检测法以及基于贝叶斯正则化的 Elman 神经网络构建 AEM，AEM 的构建思路流程如图 1 所示。

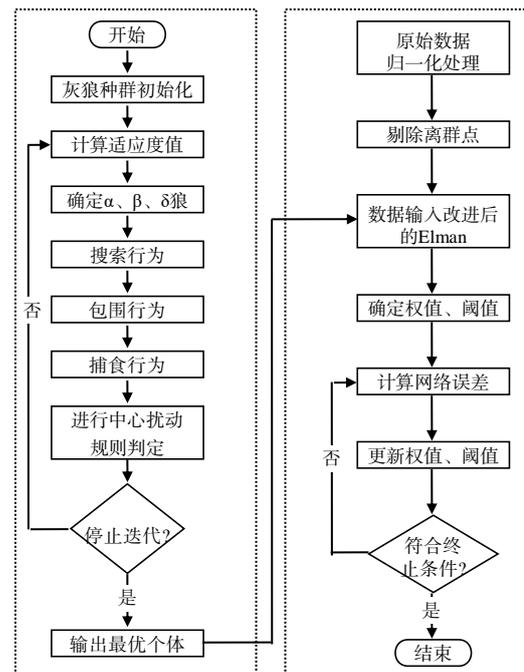


图 1 自适应进化模型流程

Fig.1 Adaptive evolution model flow

## 2 验证试验

为验证 AEM 在土壤重金属预测领域中的有效性,在同等试验环境下,将 SIDIM、CBSA-WNN、SBGRNN 及 Elman 神经网络模型作为对比模型,进行土壤重金属含量预测试验。为确保对比试验的公平性,在 Window10 操作系统下使用 Python 编程语言和 PyCharm、Matlab 等软件工具进行试验。

### 2.1 对比试验数据的选择与预处理

预测试验的数据集为武汉市土壤重金属含量数据集。这份数据是由武汉市农业科学院严格按照 HJ/T 166—2004《土壤环境检测技术规范》,根据农作物种类和土壤类型,结合 GPS 定位信息整理而成。这份数据集中包含了纬度、经度、海拔高度以及 As、Zn、Cd、Cr、Cu、Hg、Pb、Ni 等 8 种元素含量。数据集中各种重金属含量统计如表 1 所示。

表 1 重金属含量统计

Table 1 Statistics on heavy metal contents $\mu\text{g/g}$				
重金属	最小值	最大值	均值	标准偏差
As	0.24	82.07	10.15	6.00
Zn	15.16	293.73	71.17	29.29
Cd	0.01	4.94	0.21	0.39
Cr	1.611	6.701	1.799	1.789
Cu	2.16	159.36	26.21	14.06
Hg	0.01	2.37	0.14	0.17
Pb	1.96	83.30	19.46	8.60
Ni	3.32	77.67	28.22	12.04

不同农作物的种植区域内重金属的分布情况存在差异,采样点的农作物种类和土壤重金属含量

之间存在一定的相关性。此外,不同重金属之间也存在一定的相关性。为了提高重金属预测的精度,选择农作物种类和不同重金属含量信息作为模型的输入。根据预试验结果,选取 As 含量作为预测数据,计算其余 7 种重金属含量与 As 含量的相关性,并以皮尔逊相关系数作为评判指标,计算结果如表 2 所示。

表 2 7 种重金属和 As 的皮尔逊相关系数

Table 2 Pearson correlation coefficients between 7 heavy metals and As

重金属	皮尔逊相关系数	重金属	皮尔逊相关系数
Ni	0.665	Cr	0.235
Pb	0.636	Cu	0.148
Zn	0.423	Hg	0.041
Cd	0.323		

由表 2 可知,在皮尔逊相关系数的计算结果中,排名前 4 的重金属分别为 Ni、Pb、Zn 和 Cd;因此,选取这 4 种重金属含量和纬度、经度、海拔高度、农作物种类共 8 项指标作为预测模型的输入对元素 As 的含量进行预测。对比试验选择整理后的 1 000 组数据作为训练数据,30 组数据作为测试数据。在对数据进行训练之前,对数据进行归一化处理。

### 2.2 对比试验结果与分析

#### 2.2.1 预测值和真实值差距分析

5 种预测模型下的 As 含量预测值与真实值对比如图 2 所示。由图 2 可知,Elman 和 SBGRNN 中预测值和真实值之间的差值较大,且二者模型中预测值走势与真实值走势差距较大;SIDIM、CBSA-

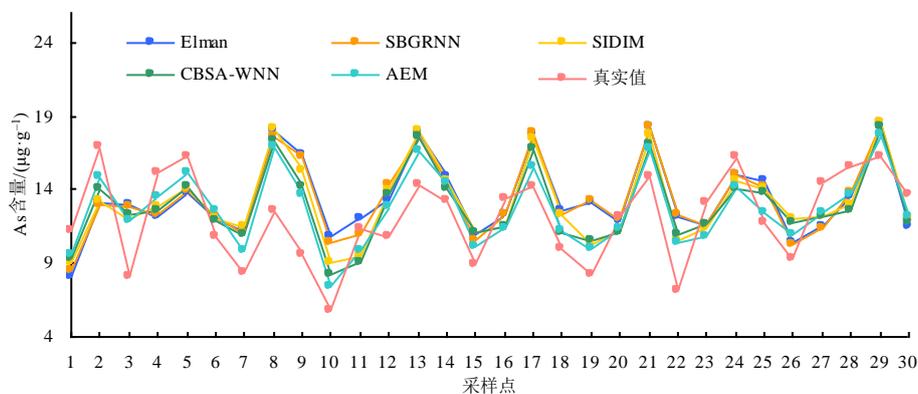


图 2 5 种模型下的 As 含量的预测值

Fig.2 The predicted values of As content of 5 prediction models

WNN 和 AEM 中预测值走势趋近于真实值走势,其中 AEM 模型预测值与真实值之间的重合度高于 SIDIM 和 CBSA-WNN 的,说明 AEM 模型更符合真实值的走势,其预测效果较准确。

为了更直观地对比 5 种模型的预测结果中真实值与预测值之间的差距,求出两者的差值与其真实值的比值,并分 $[0, 10\%]$ 、 $(10\%, 20\%]$ 、 $(20\%, 30\%]$ 、 $(30\%, 40\%]$ 、 $(40\%, \infty)$ 等 5 个比值区间进行统计,

结果如表 3 所示。从表 3 可知,5 种预测模型中,Elman 中预测差值与真实值比值大于 20% 的 3 个区间的点均最多,而 AEM 模型中预测差值与真实值比值大于 20% 的 3 个区间的点均最少。可见,5 种预测模型中,Elman 的真实值和预测值之间的差距最大,其预测精度最低,而 AEM 的真实值和预测值之间的差距最小,其预测效果最好。

表 3 5 种模型中 30 个预测点的差值分布

Table 3 Distribution of difference in 30 predicted points in 5 models

模型	预测点数				
	$[0, 10\%]$	$(10\%, 20\%]$	$(20\%, 30\%]$	$(30\%, 40\%]$	$(40\%, \infty)$
Elman	2	5	10	6	7
SBGRNN	4	8	9	5	4
SIDIM	4	13	9	1	3
CBSA-WNN	6	15	5	2	2
AEM	9	16	2	1	2

## 2.2.2 不同模型的预测精度对比分析

5 种预测模型的均方误差(MSE)、平均绝对误差(MAE)、均方根误差(RMSE)、平均绝对百分比误差(MAPE)和决定系数( $R^2$ )如表 4 所示。从表 4 可知,Elman、SBGRNN、SIDIM、CBSA-WNN、AEM 的 4 项误差指标值均依次降低,AEM 的 MAE、MSE、RMSE 和 MAPE 指标值分别为 1.623、4.418、2.102 和 17.48%;AEM 的  $R^2$  为 0.865,比其他 4 种模型

高,较 Elman 的提高了 0.394。可见,5 种预测模型中,AEM 的预测性能最好。

## 2.3 消融试验

构建 Elman、贝叶斯-Elman、贝叶斯-灰狼-Elman 与 AEM 等 4 种模型进行消融试验。消融试验使用的数据集与预测试验一致,随机选取其中 600 组数据作为本次预测试验的样本数据,之后从 600 组样本数据中随机选取 60 组数据作为预测数据,其余 540 组数据作为训练数据。预测试验选取 Cr 含量作为预测数据,对比其余 7 种元素含量和 Cr 含量的相关性,并以皮尔逊相关系数作为评判指标。在皮尔逊相关系数的计算结果中,排名前 5 的重金属分别为 Ni、Pb、As、Zn 和 Cd;因此,选取以上 5 种重金属作为预测模型的输入对 Cr 含量进行预测。消融试验结果如表 5 所示。

表 4 5 种预测模型预测结果的误差

Table 4 Errors of 5 prediction models in predicting results

模型	MAE	MSE	MAPE/%	RMSE	$R^2$
Elman	4.437	6.703	25.09	2.589	0.471
SBGRNN	2.111	6.101	21.99	2.470	0.545
SIDIM	2.006	5.885	20.05	2.426	0.615
CBSA-WNN	1.786	5.345	18.26	2.312	0.702
AEM	1.623	4.418	17.48	2.102	0.865

表 5 消融试验结果

Table 5 Results of ablation test

模型	贝叶斯正则化	自适应灰狼算法	基于熵权距离的离群点检测	MAE	MAPE/%	MSE
Elman				7.063	20.31	8.654
贝叶斯-Elman	√			5.802	19.01	7.349
贝叶斯-灰狼-Elman	√	√		3.112	17.13	4.768
AEM	√	√	√	2.086	16.02	2.963

由表 5 可知：使用基于贝叶斯正则化的 Elman 神经网络构建预测模型的 MAE、MSE 和 MAPE 分别为 5.802、7.349 和 19.01%；相比于传统 Elman 神经网络模型，贝叶斯-Elman 模型 3 项指标分别降低了 1.261、1.305 和 1.30 个百分点，说明使用贝叶斯对 Elman 神经网络的损失函数进行优化，可以提高模型的预测精度；在贝叶斯-Elman 模型基础上，引入自适应灰狼算法对 Elman 神经网络的初始参数进行优化，可进一步提高模型的预测精度；引入自适应灰狼算法改进后的模型的 MAE、MSE 和 MAPE 分别为 3.112、4.768 和 17.13%，相比于改进前模型的 3 项指标分别降低了 2.690、2.581 和 1.88 个百分点；在贝叶斯-灰狼-Elman 模型基础上，引入基于熵权距离的离群点检测的 AEM 的预测准确度更高，其 MAE、MSE 和 MAPE 分别为 2.086、2.963 和 16.02%，AEM 与贝叶斯-灰狼-Elman 模型相比，3 项指标分别降低了 1.026、1.805 和 1.11 个百分点，说明使用基于熵权距离的离群点检测法剔除数据中的离群点后，可以有效提升模型的预测精度。综上所述，贝叶斯正则化优化、自适应灰狼算法优化和基于熵权距离的离群点检测的离群点数据剔除等 3 个改进点对于提升土壤重金属含量预测精度均有一定的贡献。

### 3 结论

本研究中，笔者建立了一种自适应进化模型下的土壤重金属含量预测模型。该模型采用自适应灰狼算法对改进后的 Elman 神经网络进行优化，从而在提升 Elman 神经网络模型收敛速度的同时，增加其数据预测准确度。将 AEM 与 Elman、SBGRNN、SIDIM、CBSA-WNN 等模型在同等环境下进行对比试验，结果表明，AEM 的真实值走势和预测值走势更为接近，预测准确度更高，模型收敛速度最快，可用于土壤重金属含量预测。但 AEM 模型也存在着数据量过大，导致模型训练时间过长的问题。下一步可探索如何解决这一问题，并在更多实际问题中运用该模型。

### 参考文献：

[1] 许洪扬, 付冰清, 康慧, 等. 铅锌矿渣污染土壤的重金属含量及真菌群落特征分析[J]. 湖南农业大学学报(自

然科学版), 2021, 47(2): 203-211.

- [2] ECH-CHAREF A, DEKAYIR A, JORDÁN G, et al. Soil heavy metal contamination in the vicinity of the abandoned Zeïda Mine in the Upper Moulouya Basin, Morocco: implications for airborne dust pollution under semi-arid climatic conditions[J]. *Journal of African Earth Sciences*, 2023, 198: 104812.
- [3] 袁余洋, 刘属灵, 刘永林, 等. 重庆江津区自产大米和玉米中重金属的健康风险评估[J]. 湖南农业大学学报(自然科学版), 2021, 47(6): 677-683.
- [4] LU Z C, SU H F. Correction to: employing gene chip technology for monitoring and assessing soil heavy metal pollution[J]. *Environmental Monitoring and Assessment*, 2022, 194: 231.
- [5] DUAN C Q, WANG B Q, LI J X. Prediction model of soil heavy metal content based on particle swarm algorithm optimized neural network[J]. *Computational Intelligence and Neuroscience*, 2022, 2022: 9693175.
- [6] 李洋莹, 陈智军, 张子豪, 等. 基于改进 Elman 神经网络的制糖企业原糖需求预测模型[J]. *计算机应用*, 2021, 41(7): 2113-2120.
- [7] 张俊杰. 基于深度强化学习的土壤重金属含量预测方法研究[D]. 武汉: 武汉轻工大学, 2021.
- [8] 曹文琪. 基于神经网络及智能算法的土壤重金属含量预测方法研究[D]. 武汉: 武汉轻工大学, 2021.
- [9] 林靖皓, 秦亮曦, 苏永秀, 等. 基于自注意力机制的双向门控循环单元和卷积神经网络的芒果产量预测[J]. *计算机应用*, 2020, 40(S1): 51-55.
- [10] 肖茂华, 周爽, 黄天逸, 等. 参数优化 VMD-MPE 和 PSO-CS-Elman 神经网络在滚动轴承故障诊断中的应用研究[J]. *振动工程学报*, 2023, 36(3): 861-874.
- [11] 李晓宇, 叶春明. 改进灰狼优化算法在炼钢过程中的应用[J]. *软件导刊*, 2022, 21(10): 115-122.
- [12] 宋玉生, 刘光宇, 朱凌, 等. 改进的灰狼优化算法在 SVM 参数优化中的应用[J]. *传感器与微系统*, 2022, 41(9): 151-155.
- [13] RAJAGOPALAN A, NAGARAJAN K, MONTOYA O D, et al. Multi-objective optimal scheduling of a microgrid using oppositional gradient-based grey wolf optimizer[J]. *Energies*, 2022, 15(23): 9024.
- [14] 伍权, 朱萌, 陈磊, 等. 基于贝叶斯正则化 BP 神经网络的超临界二氧化碳流动阻力特性预测[J]. *热力发电*, 2022, 51(6): 50-58.
- [15] BOUALEM S, KRAA O, BENMEDDOUR M, et al. Power management strategy based on Elman neural network for grid-connected photovoltaic-wind-battery hybrid system[J]. *Computers and Electrical Engineering*, 2022, 99: 107823.
- [16] QI Z, CHEN X M. A novel density-based outlier detection method using key attributes[J]. *Intelligent Data Analysis*,

- 2022, 26(6): 1431–1449.
- [17] 尹成祥, 张宏军, 张睿, 等. 基于加权距离的局部离群点检测算法[J]. 科学技术与工程, 2014, 14(15): 79–82.
- [18] PARK J, SHIN H. Vascular aging estimation based on artificial neural network using photoplethysmogram waveform decomposition: retrospective cohort study[J]. JMIR Medical Informatics, 2022, 10(3): e33439.
- [19] 赵雪, 顾伟红. 基于 GRA-SSA-Elman 的隧洞 TBM 掘进适应性评价[J]. 隧道建设(中英文), 2022, 42(11): 1879–1888.
- [20] MALIK S, ALI KHAN K, NOSHEEN A, et al. Generalization of Montgomery identity via Taylor formula on time scales[J]. Journal of Inequalities and Applications, 2022, 2022: 24.
- [21] 林小雨, 江岳文, 温步瀛. 基于逼近和牛顿插值法的最佳风电接纳水平确定[J]. 电力系统保护与控制, 2015, 43(18): 12–17.
- [22] 李佳园, 李耀南, 惠继录. 灰狼优化算法的应用综述[J]. 数字技术与应用, 2022, 40(9): 10–13.
- [23] 王玉芳, 曾亚志, 蒋亚飞. 基于自适应灰狼优化算法的柔性作业车间调度问题[J]. 现代制造工程, 2022(7): 1–10.
- [24] DAS D, KAYAL P, MAITI M. A K-means clustering model for analyzing the Bitcoin extreme value returns[J]. Decision Analytics Journal, 2023, 6: 100152.
- [25] 张忠平, 刘伟雄, 张玉停, 等. ERDOF: 基于相对熵权重密度离群因子的离群点检测算法[J]. 通信学报, 2021, 42(9): 133–143.

责任编辑: 邹慧玲

英文编辑: 柳正

(上接第 104 页)

- [8] HAKIM M, OMRAN A A B, AHMED A N, et al. A systematic review of rolling bearing fault diagnoses based on deep learning and transfer learning: taxonomy, overview, application, open challenges, weaknesses and recommendations[J]. Ain Shams Engineering Journal, 2023, 14(4): 101945.
- [9] GUNDEWAR S K, KANE P V. Bearing fault diagnosis using time segmented Fourier synchrosqueezed transform images and convolution neural network[J]. Measurement, 2022, 203: 111855.
- [10] ZHOU C J, MA J, WU J D. Fault diagnosis of check valve based on CEEMD compound screening, BSE and FCM[J]. IFAC-PapersOnLine, 2018, 51(21): 323–328.
- [11] YUAN X Y, FAN Y G, ZHOU C J, et al. Fault diagnosis of check valve based on KPLS optimal feature selection and kernel extreme learning machine[J]. Coatings, 2022, 12(9): 1320.
- [12] 冯泽仲, 熊新, 王晓东. 基于循环频谱相干和 DCNN 的隔膜泵单向阀故障诊断方法研究[J]. 振动与冲击, 2021, 40(14): 237–244.
- [13] 熊力, 刘宁, 童成彪, 等. 单向阀微弱内泄漏故障特征提取与模式识别研究[J/OL]. 机械科学与技术: 1–9. (2022–11–08)[2022–12–04]. <https://doi.org/10.13433/j.cnki.1003-8728.20220293>.
- [14] TONG C B, SEPEHRIN, ZHOU J. Root cause detection of leakage in check valves using multi-scale signal analysis[J]. Journal of Mechanical Science and Technology, 2023, 37(1): 55–67.
- [15] 梁立民. 液压系统的泄漏及其防治[J]. 同煤科技, 2013(4): 38–40.
- [16] 肖雄, 王健翔, 张勇军, 等. 一种用于轴承故障诊断的二维卷积神经网络优化方法[J]. 中国电机工程学报, 2019, 39(15): 4558–4568.
- [17] 常亮, 邓小明, 周明全, 等. 图像理解中的卷积神经网络[J]. 自动化学报, 2016, 42(9): 1300–1312.
- [18] 刘建伟, 赵会丹, 罗雄麟, 等. 深度学习批归一化及其相关算法研究进展[J]. 自动化学报, 2020, 46(6): 1090–1120.
- [19] 陆克中, 陈超凡, 蔡桓, 等. 面向概念漂移和类不平衡数据流的在线分类算法[J]. 电子学报, 2022, 50(3): 585–597.

责任编辑: 邹慧玲

英文编辑: 柳正