

蜣螂算法优化 CNN-LSTM-AT 模型的 异常用电行为检测方法

于多^{1,2†}, 钱承山³, 毛伟民³

(1. 南京信息工程大学自动化学院, 江苏 南京 210044; 2. 无锡职业技术学院控制工程学院, 江苏 无锡 214121;
3. 无锡学院, 江苏 无锡 214100)

摘要:针对用电模型预测精度不高导致异常检测效率低的问题, 本文提出使用蜣螂优化算法(DBO)对卷积神经网络(CNN)-长短期记忆网络(LSTM)-注意力机制(AT)模型进行超参数选择的方法。首先, 用户用电数据经过处理后, 使用 CNN 对数据进行特征提取, 用作 LSTM 的输入以分析时间序列, 注意力机制提取 LSTM 隐藏状态的重要特征, 忽略无用特征, 逐步提高预测精度。其次利用 DBO 算法对 CNN 卷积层的特征检测器大小、LSTM 网络的神经元大小和 Dropout 的大小进行优化, 以提高模型性能, 进而将预测结果与用户的用电数据进行比较和异常判断。最后, 将本文所提方法在办公区域用电数据集上进行实验, 实验验证了所提方法的有效性。

关键词:异常用电; 蜣螂优化算法; 注意力机制; 卷积神经网络; 长短期记忆网络

中图分类号: TM73

文献标识码: A

Abnormal Electrical Behavior Detection Method of DBO-CNN-LSTM Based on Attention Mechanism

YU Duo^{1,2†}, QIAN Chengshan³, MAO Weimin³

(1. School of Automation, Nanjing University of Information Science & Technology, Nanjing, Jiangsu 210044, China;
2. School of Control Technology, Wuxi Institute of Technology, Wuxi, Jiangsu 214121, China;
3. Wuxi University, Wuxi, Jiangsu 214100, China)

Abstract: Aiming at the problem that the prediction accuracy of the electricity consumption model is not high, resulting in low anomaly detection efficiency, this paper proposes a method for hyperparameter selection of convolutional neural network (CNN)-long short-term memory network (LSTM)-attention mechanism (AT) model using dung beetle optimization algorithm (DBO). Firstly, after the user's electricity data is processed, the CNN extracts the features of the data, which is used as the input of the LSTM to analyze the time series, and the attention mechanism extracts the important features of the hidden state of the LSTM, ignores the useless features, and gradually improves the prediction accuracy. Secondly, the DBO algorithm is used to optimize the size of the feature detector of the CNN convolutional layer, the neuron size of the LSTM network and the size of Dropout, so as to improve the performance of the model, and then compare the prediction results with the user's power consumption data and make abnormal judgment. Finally, the proposed method is experimented on the electricity consumption dataset of the office area, and the effectiveness of the proposed method is verified by experiments.

Key words: abnormal electricity consumption; dung beetle optimization algorithm; attention mechanisms; convolutional neural networks; long short-term memory networks

异常检测是指在数据中发现不符合预期行为模式的问题^[1],异常检测可以通过识别用户的不良用电行为来减少不必要的能源浪费,如下班不关空调和电脑等不良用电习惯,异常检测还可以识别窃电行为,据不完全统计,我国因窃电引起的损失占全国总电量的 6.42%^[2]。通过识别用户的异常用电行为,可以提高能源效率、减少能源支出、节约用电成本^[3],实现有序用电和能源管理^[4]。

物联网技术的发展以及智能电表的普及为用户获得细粒度的用电数据提供了样本支撑,目前,基于数据驱动的用电异常行为的检测方法受到重视^[5]。基于数据驱动的用电异常行为的检测方法主要包括分类、聚类和回归等方法^[6],文献[7]使用支持向量机(SVM)对用电数据进行训练,通过分类的方法将用电行为分为正常和异常两类,虽然能有效地检测用户的异常用电行为,但是需要人工提取用电数据的特征。文献[8]使用 K-means 聚类的方法,对预测的数据进行聚类分析,将相似度高的用电数据聚为一类,并计算样本与聚类中心的偏移程度,用于区分正常用电和异常用电。文献[9]采用基于密度权重的改进 K-medoids 算法将异常数据依据表征指标进行标签化聚类,采用 SVM 分类器步完成异常参数的检测和评估,聚类采用的是无监督学习方式,其对初始参数的选取依赖太强。基于回归的异常检测模型是使用历史用电数据预测未来用电数据,当预测值与实际值之间存在较大偏差时(例如,实际值大于预测阈值),检测为异常,因此回归法的用电异常检测依赖于对未来用电数据的预测精度。在用电负荷预测方面,文献[10]使用 CNN 提取时序数据存在的潜在特征为 LSTM

提供有效的输入数据,实现用电负荷的预测,实验结果证明预测精度比仅使用 LSTM 模型的高。文献[11]指出单一的 CNN 模型不能较好地学习用电数据的动态变化规律,文献[12]说明 LSTM 可以很好地读取时序特征,但是对于长时间序列,容易丢失序列信息,并加入注意力机制提取 LSTM 隐藏状态的重要特征。综上考虑,本文使用基于注意力机制的 CNN-LSTM 模型对用电数据进行预测,又由于模型的超参数选择依赖于经验,且超参数的调整较复杂,影响模型的预测和精度。

本文针对用电模型预测精度不高的问题,使用 DBO 优化算法对 CNN-LSTM-AT 模型进行超参数选择,该模型用于对用电数据的总功率进行预测。首先,用户的用电数据经过处理后,使用 CNN 对其进行特征提取,通过卷积、池化操作后形成新的时间序列特征;针对时间序列特点,使用 LSTM 方法分析时间序列,注意力机制赋予 LSTM 的不同隐藏状态概率权重,提取重要特征,忽略无用特征,逐步提高预测精度。其次利用 DBO 算法优化模型的超参数,以提高模型性能。最后,该方法在办公室用电数据集上进行实验,实验验证了所提方法的有效性。

1 预测模型的建立

CNN-LSTM-AT 混合模型的结构如图 1 所示。CNN 主要从数据中提取用电特征,获得的特征经过卷积、池化后,用作 LSTM 的输入以分析时间序列特征,注意力机制提取 LSTM 隐藏状态的重要特征,用来完成数据的预测。




图 1 CNN-LSTM-AT 混合模型结构

1.1 卷积神经网络

CNN 的输入层从数据集接收输入数据,卷积层通过设置特征检测器大小和卷积核大小完成特征提取,其卷积计算过程如式(1)所示。池化层压缩卷积层的数据量,从而减少过拟合,池化后的数据作为 LSTM 的输入进行处理时间序列。

$$A_{ij} = f(\sum_{i,j}^n (W_{(n-i)(n-j)} x_{ij} + b_{ij})) \quad (1)$$

其中, $f(\cdot)$ 代表激活函数, A_{ij} 代表卷积后的特征图, W 代表权重, b 代表偏置。

1.2 长短期记忆网络

LSTM 是一种特殊的递归神经网络(RNN)^[13], LSTM 通过存储单元存储有用信息并消除不必要的信息来解决 RNN 的梯度消失和梯度爆炸问题,因此 LSTM 可以学习长期依赖关系。

每个 LSTM 单元由一个存储单元和三个门组成:输入门、输出门和遗忘门。

遗忘门 f_t 的式为:

$$f_t = \sigma(W_f x_t + W_f h_{t-1} + b_f) \quad (2)$$

其中, σ 是 Sigmoid 激活函数, W_f 和 b_f 分别表示当前 t 时刻,遗忘门的权重矩阵和偏差。 h_{t-1} 是 $(t-1)$ 时刻的隐藏状态, x_t 是 t 时刻的输入数据,它根据隐藏状态决定应该丢弃哪些 h_{t-1} 和输入 x_t 。

输入门的式为:

$$i_t = \sigma(W_i x_t + W_i h_{t-1} + b_i) \quad (3)$$

$$c_t^* = \tanh(W_{c^*} x_t + W_{c^*} h_{t-1} + b_{c^*}) \quad (4)$$

更新的中间状态变量式是:

$$c_t = f_t \cdot c_{t-1} + i_t \cdot c_t^* \quad (5)$$

输出门的式为:

$$o_t = \sigma(W_o x_t + W_o h_{t-1} + b_o) \quad (6)$$

最后,当前神经单元的输出为:

$$h_t = o_t \cdot \tanh(c_t) \quad (7)$$

式中, $\tanh$ 是正切函数, $\cdot$ 表示向量之前的相乘。可以看出 LSTM 可以处理连续的时间序列数据,且在 LSTM 层堆叠在一起的情况下,每个 LSTM 层的存储状态 c_t 和隐藏状态 h_t 都输入到下一个 LSTM 层。

1.3 注意力机制

注意力机制^[14]模仿人类的视觉观察,在训练中关注与目标相关性高的状态。因此注意力机制选择性地考虑重要特征,而不是关注所有特征,从而通过消除不重要特征来提高计算效率,并且可以提高预测精度。本文所提模型应用注意力机制来提取 LSTM 的重要隐藏状态。注意力机制应用在 LSTM 层之后,其结构如图 2 所示。

在 t 时刻,每个 LSTM 隐藏状态的注意力权重可以通过使用 LSTM 先前隐藏状态




图 2 注意力机制 LSTM 结构图

S_{t-1} 计算如式(8)和式(9)所示。

$$\alpha_i^t = Z_a^T \tanh(W_a S_{t-1} + U_a h_i) \quad (8)$$

$$\beta_i^t = \frac{\exp(\alpha_i^t)}{\sum_{j=1}^T \exp(\alpha_j^t)} \quad (9)$$

其中, Z_a 、 W_a 、 U_a 是权重,需要训练得到。 α_i^t 表示在时间 t 时刻, LSTM 隐藏状态与目标相关的注意力权重。使用 softmax 激活函数来获得 β_i^t , 其表示第 i 个 LSTM 隐藏状态的重要性, t 时刻的输出为隐藏状态与注意力概率的加权和如式(10)所示。

$$O_t = \sum_{i=1}^T \beta_i^t h_i \quad (10)$$

因此,这个变量代表不同的输入和序列值在预测输出中的重要性。

1.4 蜥蜴优化算法

蜥蜴优化算法(DBO)是根据蜥蜴的滚球、跳舞、觅食、偷窃和繁殖行为而设计的全局探索和局部开发的优化算法^[15]。蜥蜴是以动物的粪便为食,并将粪便打成球,粪球不仅可用来产卵和养育下一代,而且可用作蜥蜴的食物,其工作流程图如图 3 所示。

1.4.1 蜥蜴滚球

在滚动过程中,如果没有障碍物,蜥蜴会利用太阳进行导航,滚动球的蜥蜴位置会更新,可以表示为:

$$x_i(t+1) = x_i(t) + \alpha \cdot k \cdot x_i(t-1) + b \cdot |x_i(t) - X^{\text{worst}}| \quad (11)$$

其中, t 表示当前迭代的次数, $x_i(t)$ 表示第 i 只蜥蜴在第 t 次迭代时的位置信息, $k \in (0, 0.2]$ 表示偏转系数的常数值, b 是在 $(0, 1)$ 之间的常数,

α 是 -1 或者 1 的自然系数。 X^{worst} 表示全局最差位置, $|x_i(t) - X^{\text{worst}}|$ 用于模拟光强的变化。

1.3.2 蜚螂繁殖

蜚螂将粪球滚到安全的地方,为后代提供一个安全环境,蜚螂产卵的区域公式为:

$$\begin{cases} \text{Lb}^* = \max(X^* \cdot (1 - R), \text{Lb}) \\ \text{Ub}^* = \min(X^* \cdot (1 + R), \text{Ub}) \end{cases} \quad (12)$$

X^* 表示当前种群的最佳位置, Lb^* 和 Ub^*

分别表示产卵区的下限和上限, $R = 1 - \frac{t}{T_{\max}}$, $T_{\max}$ 表示最大迭代次数, Lb 、 Ub 分别表示优化问题的下界和上界。

1.3.3 蜚螂觅食

小蜚螂的最佳觅食区域边界定义为:

$$\begin{cases} \text{Lb}^b = \max(X^b(1 - R), \text{Lb}) \\ \text{Ub}^b = \min(X^b(1 + R), \text{Ub}) \end{cases} \quad (13)$$

其中, X^b 表示全局最佳位置, Lb^b 和 Ub^b 分别表示最佳觅食区域的下限和上限。

1.3.4 蜚螂偷窃

在种群中,蜚螂也会偷窃其他蜚螂的食物,在迭代过程中,小偷的位置信息公式为:

$$x_i(t+1) = X^b + S \cdot \mathbf{g} \cdot (|x_i(t) - X^*| + |x_i(t) - X^b|) \quad (14)$$

其中, $x_i(t)$ 表示第 t 次迭代中第 i 个小偷的位置信息, $\mathbf{g}$ 是一个大小为 $1 \times D$ 的随机向量,遵循正态分布, S 表示一个常量。

1.4.5 种群划分

一个种群按照 6 : 6 : 7 : 11 的比例对蜚螂划分成不同的角色。本文以 30 个个体为例,6 个蜚螂用于滚球行为,6 个蜚螂用于繁殖行为,7 个为小蜚螂觅食行为,11 个蜚螂用于偷窃行为。

1.5 数据来源与数据准备

本实验使用了一个办公室 19 天(2023 年 3 月 13 日至 2023 年 3 月 31 日)的用电数据,数据包括电压、电流、功率、天气四个特征。办公室用电设备主要包括一台笔记本电脑,一台台式电脑,一台打印复印一体机、一台小型打印机和一台柜式空调,数据采集的频率是 1 次/min,共 23040 条数据,其中,21600 条数据用于模型训练,剩余的 1440 条数据用于模型测试。图 4 显示工作日 2 天的用电总功率数据,从图 4 可以看出,办公室用电主要集中在早上 9 点至下午 5 点之间,图 4(a)的总功率整体偏高,是因为当天天气阴冷,办公室开了空调,图 4(b)是没有开空调的用电总功率数据展示,总功率较低,但是会偶尔出现瞬时功率上升的现象,是

因为打印复印一体机刚开机的瞬间会产生用电峰值,产生的峰值不利于模型的学习。为了使数据更加稳定,训练更容易,收敛速度更快,首先对数据进行移动平均处理,移动平均处理是将每 15 分钟的数据进行平均取值,移动平均处理后,再对数据归一化,如式(11)所示。

$$\hat{P} = \frac{P - P_{\min}}{P_{\max} - P_{\min}} \quad (15)$$

其中, $\hat{P}$ 是归一化后的用电总功率数据, P 是归一化前的用电总功率数据, $P_{\max}$ 和 $P_{\min}$ 分别是用电总功率的最大和最小值。




图 3 DBO 优化算法工作流程图

本实验滑动窗口大小为 5,即使用 5 个时间步长的数据预测下一个时间点的数据。使用 CNN 对用电数据进行特征提取,提取后的数据进入 LSTM 网络对时间序列进行预测,并使用注意力机制对 LSTM 网络的隐藏状态进行重要信息提取,忽略不重要信息,DBO 算法迭代 50 次对 CNN-LSTM-AT 模型的 CNN 卷积层的特征检测器大小、LSTM 网络的神经元大小和 Dropout 的大小进行参数寻优,最终完成用电数据的预测,预测模型的算法流程图如图所示 5 所示。

2 异常检测方法

2.1 模型参数设置

本文提出的模型 CNN 层使用一层卷积,一层池化,卷积核大小为 2,池化层的大小为 2, LSTM

网络分为两层,每层网络后都使用相同的 Dropout,注意力机制应用在 LSTM 网络输出后。模型搭建好后,使用 DBO 优化算法寻找本文提出模型的特征检测器大小、神经元大小和 Dropout,经过

实验得到 CNN 卷积层的特征检测器大小为 131, LSTM 第一层网络神经元大小是 195,第二层网络神经元大小是 144,Dropout 为 0.001。模型使用的训练次数为 50,批量大小是 128。




图 4 工作日 2 天的用电总功率




图 5 DBO-CNN-LSTM-AT 预测模型
算法流程图

2.2 模型的评价指标

本实验使用拟合模型来预测整个数据集,通过计算出预测与实际值计算差值,并选用以下两种评价指标:

平均绝对误差(MAE):

$$MAE = \frac{1}{N} \sum_{t=1}^N |y_t - \hat{y}_t| \tag{16}$$

均方根误差(RMSE):

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2} \tag{17}$$

其中, y_t 是实际值, $\hat{y}_t$ 是预测值, N 是用电数据样本的总个数。以上二种评价指标 MAE 和 RMSE 的数值越小,则模型的预测精度越高。

2.3 异常检测方法

使用已构建的时间序列模型预测下一个时间

戳的数值,计算实际值和预测值之间的差。为了正确检测异常用电行为,本文使用绝对误差和欧几里得距离作为差异的度量,式(14)和式(15)分别表示绝对误差和欧几里得距离。

$$(y_t, \hat{y}_t) = y_t - \hat{y}_t$$

(18)

$$(y_t, \hat{y}_t) = \sqrt{(y_t - \hat{y}_t)^2}$$

(19)

其中, y_t 是实际值, $\hat{y}_t$ 是预测值。绝对误差所设定的阈值为 ϵ_1 , 欧几里得距离所设定的阈值为 ϵ_2 。

2.4 异常检测评估方法

表 1 给出了用于评估算法性能的混淆矩阵的具体表示方法。

表 1 混淆矩阵的表示

	检测正常	检测异常
实际正常	TP(True Positive)	FN(False Negative)
实际异常	FP(False Positive)	TN(True Negative)

式(20)–式(22)分别是准确度(AUC)、精确度(PRE)和召回率(REC)的定义。

$$AUC = \frac{TP + TN}{TP + TN + FP + FN}$$

(20)

$$PRE = \frac{TP}{TP + FP}$$

(21)

$$REC = \frac{TP}{TP + FN}$$

(22)

其中, TP 是检测正确的正常用电数据; FN 是检测正确的异常用电数据; FP 是把异常的用电数据检测为正常用电数据, 相当于漏报; TN 是把正常的用电数据检测为异常用电数据, 相当于误判。AUC 反映了正确检测与所有样本的比值, 其值越高说明整体的检测准确度高; PRE 表示正确检测正常用电数据与所有实际正常样本的比值, 其值越高说明检测正常用电数据的精确度高; REC 表示了正确检测正常用电数据与所有检测正确的样本比值, 主要关注的是正常的用电数据。本文使用 F1 分数作为 AUC 和 REC 的综合表现, 计算式如式(19)所示, 其值越高, 异常用电数据检测性能越好。

$$F1 = \frac{2 \cdot PRE \cdot REC}{PRE + REC}$$

(23)

3 实验结果与分析

3.1 预测结果对比分析

本文的异常检测是通过拟合用户的实际用电功耗进行异常检测, 为了提高异常检测的准确性, 先对用户的用电功耗进行准确预测。训练数据集和测试数据集的预测结果如图 6 和图 7 所示。




图 6 训练数据集拟合结果




图 7 测试数据集拟合结果




图 8 各模型预测结果




图 9 各模型预测绝对误差结果

为了进一步验证本文所提出的 DBO-CNN-LSTM-AT 预测模型的有效性, 使用单一模型 LSTM, 混合模型 LSTM-AT、CNN-LSTM 对用户用电数据进行预测, 各模型在 700 个测试数据集上的预测结果如图 8 所示。各模型绝对误差和欧几里得距离计算结果如图 9 和图 10 所示。表 2 为各

预测模型的评价指标。由以可知本文所提出的 DBO-CNN-LSTM-AT 预测模型拟合度好且误差小,同时可以看出混合模型的预测效果要优于单一的模型。从表 2 中可以看出, DBO-CNN-LSTM-AT 模型的 MAE 为 11.97, RMSE 为 39.59, 与其他模型相比, 具有较低的 MAE 和 RMSE, 预测精度相对更高。




图 10 各模型欧几里得距离结果

表 2 各模型评价指标

算法模型	MAE	RMSE
LSTM	20.43	51.5
LSTM-AT	25.43	49.27
CNN-LSTM	18.41	42.77
DBO-CNN-LSTM- AT	11.97	39.59

3.3 异常检测实验结果分析

本文参考文献[3]的方法,在 700 个测试数据中插入 14 个异常值,用来测试异常检测效果。从 19 天的数据来看,一台笔记本正常运行最低功率为 60 W 左右,一台台式机电脑正常运行功率为 110 W

左右,因此阈值设置为 60,用来标记时间序列中的单个异常点,异常检测的结果如图 11 所示。图 12 是四种模型的混淆矩阵,从图 12 可知,本文提出的模型 TP 为 660, FN 为 26, FP 为 4, TN 为 10, 本文一共 14 个异常点,正确检查异常点的个数是 10。表 3 为各模型异常检测算法评价性能,从表 3 可知本文所提的模型的 F1 分数最高。综上,本文所提出的模型的异常检测能力相对较高。

3.4 办公室异常检测结果分析

将本文所提的模型应用在办公室的用电行为检测上,一般正常下班后,所有电脑和空调关闭后,用电总功率基本为 0,如果存在不关空调或不关电脑的用电行为,用电总功率至少大于 60 W 且异常是连续的, ϵ_1 、 ϵ_2 设置为 60,如图 13 所示,在 18:00 后检测到功率大于预测且是连续的,可通知相关负责人进行检查确认。




图 11 异常用电行为检测




图 12 混淆矩阵

表 3 各模型异常检测对比

模型	准确度	精确度	召回率	F1 分数
LSTM	0.86	0.08	0.64	0.16
LSTM-AT	0.96	0.25	0.64	0.36
CNN-LSTM	0.96	0.26	0.5	0.35
DBO-CNN-LSTM-AT	0.96	0.27	0.71	0.4




图 13 办公室用电行为检测

4 结 论

提出了 DBO-CNN-LSTM-AT 的异常用电行为检测方法,该模型对用电数据的总功率进行预测,通过预测值与实际值之间的差异判断异常。所做的主要工作如下:构建了 CNN-LSTM-AT 预测模型,使用 CNN 对用电数据进行特征提取,LSTM 分析时间序列,注意力机制提取重要特征;使用 DBO 算法对模型进行参数优化,提高了模型预测精度;通过设置两个不同的阈值对异常用电行为进行判断,提高了异常用电行为检测的准确度。将本文所提模型与 LSTM、LSTM-AT、CNN-LSTM 模型进行比较验证,实验结果表明,本文提出的模型在预测精度和异常用电行为检测性能均优于其他三个模型,最后对办公室用电行为进行异常检测,验证了该方法的有效性。

参考文献

[1] CHANDOLA V, BANERJEE A, KUMAR V. Anomaly detection:a survey[J]. Computing Surveys(CSUR), 2009, 41 (3): 1-58.

[2] 郑贵林, 谢耀. 基于小波和长短期记忆混合神经网络的电力用户异常用电模式检测[J]. 电测与仪表, 2022, 59(11): 120-125+146.

[3] CHAHLA C, SNOUSSI H, MERGHEM L, et al. A deep learning approach for anomaly detection and prediction in power consumption data[J]. Energy Efficiency, 2020, 13 (8): 1633-1651.

[4] MURALIDHARA S, HEGDE N, PM R. An internet of things-based smart energy meter for monitoring device-level consumption of energy[J]. Computers & Electrical Engineering, 2020, 87: 106772.

[5] WANG P, LIN J, GUO S, et al. Distribution system data analytics and applications[J]. Power Technology, 2017, 41 (10): 3333-3340.

[6] 朱天怡, 艾芊, 贺兴, 等. 基于数据驱动的用电行为分析方法及应用综述 [J]. 电网技术, 2020, 44: 3497-3507.

[7] TSAI C W, CHIANG K C, HSIEH H Y, et al. Feature extraction of anomaly electricity usage behavior in residence using autoencoder[J]. Electronics, 2022, 11(9): 1450-1474.

[8] ZHANG J, ZHANG H, DING S, et al. Power consumption predicting and anomaly detection based on transformer and K-means [J]. Frontiers in Energy Research, 2021, 9: 779587.

[9] 胡聪, 徐敏, 洪德华, 等. 基于改进 K-medoids 聚类 and SVM 的异常用电模式在线检测方法[J]. 国外电子测量技术, 2022, 41(02): 53-59.

[10] 陆继翔, 张琪培, 杨志宏, 等. 基于 CNN-LSTM 混合神经网络模型的短期负荷预测方法 [J]. 电力系统自动化, 2019, 43: 131-137.

[11] DONG X, QIAN L, HUANG L. Short-term load forecasting in smart grid: A combined CNN and K-means clustering approach[J]. 2017 IEEE International Conference on Big Data and Smart Computing (BigComp), 2017: 119-125.

[12] 李冬辉, 刘功尚, 高龙. 基于 Inception-LSTM-Attention 的冷水机组传感器偏差故障诊断方法[J]. 中南大学学报(自然科学版), 2023, 54(1): 102-112.

[13] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural computation, 1997, 9(8): 1735-1780.

[14] VASWANI A, SHAZEER N M, PARMAR N, et al. Attention is all you need[C] //NIPS, 2017.

[15] XUE J, SHEN B. Dung beetle optimizer:a new meta-heuristic algorithm for global optimization[J]. The Journal of Supercomputing, 2022: 1-32.