

DOI: 10.19783/j.cnki.pspc.230062

基于 ISSA-CNN-GRU 模型的电动汽车充电负荷预测方法

姚芳^{1,2}, 汤俊豪^{1,2}, 陈盛华^{1,2}, 董晓红^{1,2}

(1. 省部共建电工装备可靠性与智能化国家重点实验室(河北工业大学), 天津 300000;

2. 河北工业大学电气工程学院, 天津 300000)

摘要: 电动汽车用户充电行为的随机性, 给电动汽车充电站充电负荷的短期预测带来极大挑战。针对在多因素影响下电动汽车充电站充电负荷短期预测精度低的问题, 提出一种基于改进麻雀搜索算法-卷积神经网络-门控循环神经网络(improved sparrow search algorithm-convolutional neural network-gated recurrent unit neural network, ISSA-CNN-GRU)模型的电动汽车充电站充电负荷短期预测方法。首先, 构建包含气温、日期类型、节假日 3 种充电负荷显著影响因素与历史充电负荷的输入特征矩阵。然后, 融合 CNN 在特征提取、数据降维和 GRU 神经网络在时间序列预测上的优势, 搭建 CNN-GRU 混合神经网络模型, 使用基于混合策略的 ISSA 算法优化混合神经网络模型的超参数。最后, 在优化后的 CNN-GRU 模型中输入特征矩阵实现充电站充电负荷的短期预测。以美国 ANN-DATA 公开数据集中充电站的历史负荷数据作为实际算例, 与随机森林、CNN、GRU 神经网络、CNN-GRU 模型以及分别用贝叶斯优化、粒子群优化、标准麻雀优化算法进行超参数调优的 CNN-GRU 模型相比, 实验结果表明所提方法具有更好的预测效果。

关键词: 深度学习; 卷积神经网络; 门控循环单元; 麻雀搜索算法; 电动汽车; 充电负荷

Charging load prediction method for electric vehicles based on an ISSA-CNN-GRU model

YAO Fang^{1,2}, TANG Junhao^{1,2}, CHEN Shenghua^{1,2}, DONG Xiaohong^{1,2}

(1. State Key Laboratory of Reliability and Intelligence of Electrical Equipment (Hebei University of Technology),

Tianjin 300000, China; 2. School of Electrical Engineering, Hebei University of Technology, Tianjin 300000, China)

Abstract: The randomness of EV user charging behavior poses a great challenge to the short-term prediction of EV charging station charging load. There is a problem of the influence of multiple factors, and so a short-term prediction method of charging load of electric vehicle charging stations based on an improved sparrow search algorithm-convolutional neural network-gated recurrent neural network (ISSA-CNN-GRU) model is proposed. First, an input characteristic matrix containing three significant influencing factors of charging load, that is temperature, date type, and holiday, combined with historical charging load is constructed. Then, the advantages of a CNN in feature extraction, and data dimensionality reduction combined with a GRU neural network in time series prediction are used to build a CNN-GRU hybrid neural network model, and the ISSA algorithm based on hybrid strategy is used to optimize the hyperparameters of the hybrid neural network model. Finally, the input feature matrix in the optimized CNN-GRU model realizes the short-term prediction of charging load of a charging station. Taking the historical load data of charging stations in the public dataset of ANN-DATA in the United States as an actual example, compared with the random forest, CNN, GRU neural network, CNN-GRU model and CNN-GRU model with Bayesian optimization, particle swarm optimization and standard sparrow optimization algorithms respectively, the experimental results show that the proposed method offers a better prediction.

This work is supported by the Natural Science Foundation of Hebei Province (No. E2020202131 and No. E202202056).

Key words: deep learning; convolutional neural networks; gated recurrent units; sparrow search algorithm, electric vehicles; charging loads

0 引言

自 2016 年来,中国电动汽车保有量逐年攀升,预计在 2030 年将突破 8000 万辆,由此而来的庞大的随机充电负荷会给电力系统的安全稳定运行带来巨大挑战^[1-3]。电动汽车与电网互动(vehicle to grid, V2G)技术有助于减小电动汽车充电负荷导致的电网负荷波动,同时可调度优化电动汽车充电行为。因此,提高电动汽车充电负荷预测精度,对 V2G 技术应用、电动汽车有序充电和电网安全稳定运行等方面具有重要意义^[4-5]。

与电力负荷预测相比,充电负荷的历史数据因充电行为的随机性导致存在众多为零的采样点,使其预测的难度与复杂性更高。充电负荷预测的研究方法主要分为模型法和数据驱动法。其中模型法^[6]有基于统计概率的蒙特卡洛随机模拟方法^[7]、基于排队论的随机模拟方法^[8]、基于出行链和马尔科夫过程的仿真方法^[9-10]、基于多代理系统仿真方法^[11]、交通行业起止点分析法^[12]等。然而,模型法限于缺乏真实充电负荷数据,多以数学建模或仿真进行逼近真实的行为模拟,其预测结果真实性存在局限。与之相比,数据驱动法采用真实的历史充电负荷数据,更能体现充电负荷预测结果真实性与可靠性,一般用于充电站或住宅小区的充电负荷预测。数据驱动法主要运用人工智能算法进行充电负荷的预测。传统的人工智能算法如随机森林(random forest, RF)^[13]、支持向量机^[14]、反向传播神经网络^[15]等算法,虽然具有良好的非线性数据拟合能力和参数学习能力,但对类似充电负荷历史数据的时间序列数据中的时序特征无法很好地学习,甚至破坏其中的时序完整性。

深度学习的发展为电动汽车充电负荷预测提供了新的方法。其中卷积神经网络(convolutional neural network, CNN)在处理历史数据样本时,可容忍原始数据中存在数据缺失和畸形数据,且具有强大的信息特征提取能力;循环神经网络(recurrent neural network, RNN)能够将上一步的输出保留到模型,并共同参与对下一步输出的计算中,十分适合处理时序特征数据。如文献[16]采用了 4 种具有特色的深度学习对电动汽车充电负荷进行预测,以历史充电负荷、充电时间、峰谷电价和日期类型构建特征输入,其中 GRU 神经网络获得了最佳性能;文献[17]将狮子算法和基于小生境免疫的 CNN 相结合,实例验证结果表明,该混合模型在充电负荷预测中具有较好的准确性、鲁棒性和通用性;文献[18]提出了一种基于多变量残差修正灰色模型

和长短时记忆(long-short-term memory, LSTM)网络相结合的充电站负荷预测方法,将温度与电价因素纳入灰色模型输入,仿真和实验结果表明,该方法能够提高预测的准确性。LSTM 网络属于 RNN 的一种,它解决了 RNN 处理时序数据的梯度消失与梯度爆炸问题^[19],能够更好地学习时间序列数据之间的长期依赖关系,但是仍存在参数较多和模型收敛速度较慢的问题^[20]。GRU 神经网络由 LSTM 网络优化而来,结构更加精简,预测速度进一步提高,更适用于充电负荷预测领域。研究表明,不同类型神经网络的组合模型较单独的神经网络有着更佳的预测效果。文献[21]中搭建 GRU-CNN 混合神经网络进行短期电力负荷预测,实验结果表明,混合神经网络的预测精度和评价指标均优于单独的 CNN 和 GRU 神经网络。

神经网络超参数的选取往往依据经验手动调整,效果难以保证,而利用专门的优化算法对超参数调优可显著提升神经网络性能。文献[22]提出基于贝叶斯优化的 CNN-BiGRU 混合神经网络模型,利用贝叶斯优化对模型的超参数进行调优,算例结果表明,相比单独的 CNN、GRU 神经网络和未进行超参数调优的 CNN-BiGRU,经过贝叶斯优化超参数调优的 CNN-BiGRU 预测精度明显提高。超参数优化算法众多,麻雀搜索算法(sparrow search algorithm, SSA)是一种新型的群智能优化算法,具有搜索精度高、收敛速度快和鲁棒性强等优点,自 2020 年以来便广泛应用于各种优化问题^[23]。

综上所述,本文提出一种 ISSA 算法优化 CNN-GRU 混合神经网络模型的充电站电动汽车充电负荷预测方法。该方法以气温、日期类型、节假日因素与充电站历史充电负荷数据共同构建特征矩阵作为模型输入,将 CNN 的特征提取、数据降维的特点与 GRU 神经网络对时间序列数据的处理优势相结合,搭建 CNN-GRU 模型,用 ISSA 对模型超参数调优,最后以优化后的模型进行充电负荷预测。以基于 ISSA-CNN-GRU 模型的充电负荷短期预测方法对美国加州理工大学校园内一个电动汽车充电站的数据进行预测,与基于多种神经网络及不同优化算法进行超参数调优的 CNN-GRU 模型的预测结果对比表明,所提方法具有更好的预测精度。

1 理论基础

1.1 卷积神经网络

CNN 是一种深层前馈神经网络,主要用于图像处理及自然语言处理^[24]。CNN 一般由若干个卷积块与全连接层构成,卷积块包括卷积层、激活函数和

池化层。其中，卷积层是卷积神经网络的核心，每一卷积层都有一定数量的卷积核作为特征提取器。卷积核以一定步长在输入数据上滑动平移进行卷积运算，从而得到输入特征的特征图谱，卷积核进行特征提取示意图如图 1 所示。

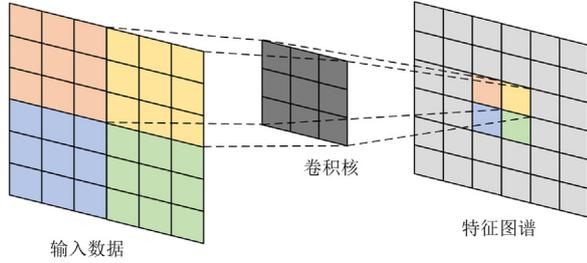


图 1 卷积核进行特征提取示意图
Fig. 1 Schematic diagram of convolution kernel for feature extraction

1.2 门控循环神经网络

GRU 神经网络由 LSTM 神经网络改进而来^[25]，二者都属于 RNN 的一种。GRU 网络作为 LSTM 网络的一种变体，将 LSTM 中的输入门和遗忘门合成一个单一的更新门，并保留重置门，在保证预测效果的同时精简了结构，减少了训练参数^[26]。GRU 基本结构如图 2 所示，数学表达式如式(1)所示。

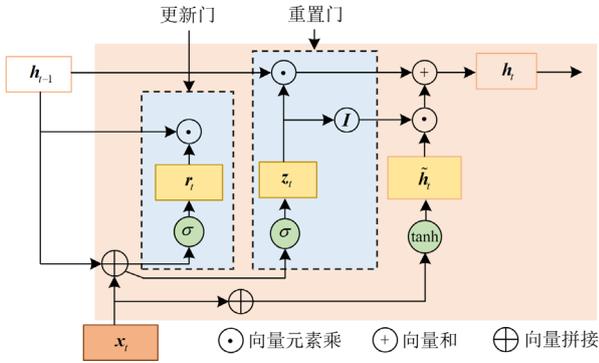


图 2 GRU 结构
Fig. 2 Structure of gated recurrent unit

$$\begin{cases} r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \\ z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \\ \tilde{h}_t = \tanh(W_{\tilde{h}} \cdot [r_t \times h_{t-1}, x_t]) \\ h_t = (I - z_t) \times h_{t-1} + z_t \times \tilde{h}_t \\ y_t = \sigma(W_o \cdot h_t) \end{cases} \quad (1)$$

式中： r_t 、 x_t 、 z_t 分别为更新门、输入门、重置门； h_{t-1} 、 h_t 、 \tilde{h}_t 分别为上一时刻的状态、当前状态、候选状态； y_t 为当前时刻的输出； W_r 、 W_z 、 $W_{\tilde{h}}$ 、

W_o 分别为更新门、重置门、候选集、输出向量的权重参数矩阵； $[\]$ 、 I 分别表示向量连接和单位矩阵；“ \cdot ”和“ \times ”表示矩阵的运算方式； σ 表示 sigmoid 激活函数。

1.3 麻雀搜索算法

SSA 是文献[27]受麻雀觅食行为启发提出的一种新型群体智能优化算法。麻雀种群分为搜寻食物并分享食物位置的发现者和追随发现者进行捕食行为的加入者，并在整个种群中随机产生 10%~20% 的侦察者负责整个觅食区域的侦查警戒。

SSA 中适应度好的麻雀被确定为发现者，其在每次迭代中的位置更新公式为

$$X_i^{t+1} = \begin{cases} X_i^t \cdot \exp\left(-\frac{i}{\beta_1 \cdot T_{\max}}\right), & R_2 < ST \\ X_i^t + \beta_2 \cdot L, & R_2 \geq ST \end{cases} \quad (2)$$

式中： X_i^t 表示在第 t 次迭代中第 i 只麻雀的位置； β_1 是一个随机数， $\beta_1 \in (0,1]$ ； β_2 为服从正态分布的随机数； R_2 为警戒阈值， $R_2 \in [0,1]$ ； ST 表示安全阈值， $ST \in [0.5,1]$ ； L 是一个与 X_i^t 具有相同维度的全 1 矩阵。当 $R_2 < ST$ 时代表周围没有危险，发现者可以广泛搜索；当 $R_2 \geq ST$ 时则代表周围有危险，发现者要转移至其他安全位置觅食。

加入者跟随发现者进行觅食，并在发现者发现更好食物时与发现者争夺食物，其位置更新公式为

$$X_i^{t+1} = \begin{cases} \beta_2 \cdot \exp\left(\frac{X_{\text{worst}}^t - X_i^t}{i^2}\right), & i > \frac{1}{2}Q \\ X_p^t + |X_i^t - X_p^t| \cdot L \cdot A^+, & i \leq \frac{1}{2}Q \end{cases} \quad (3)$$

式中： X_{worst}^t 为第 t 次迭代中种群当前最差位置； X_p^t 为第 t 次迭代中发现者最优位置； Q 为种群规模； A 是一个元素全为 1 或 -1 的一行多维矩阵， $A^+ = A^T(AA^T)^{-1}$ ， A^T 为 A 的转置矩阵。当 $i > Q/2$ 时，表示第 i 个加入者因适应度太低需要前往其他区域觅食；当 $i \leq Q/2$ ，表示加入者在发现者最佳位置周围觅食。

侦察者在发现危险时会及时发出危险信号并立即向安全区域移动，其位置更新公式如式(4)所示。

$$X_i^{t+1} = \begin{cases} X_{\text{best}}^t + \beta_3 \cdot |X_i^t - X_{\text{best}}^t|, & f_i \neq f_g \\ X_i^t + K \cdot \left(\frac{|X_i^t - X_{\text{worst}}^t|}{(f_i - f_w) + \varepsilon} \right), & f_i = f_g \end{cases} \quad (4)$$

式中： X_{best}^t 是当前全局最优位置； β_3 为一个服从标

准正态分布的随机数; K 是一个随机数, $K \in [-1, 1]$; ε 通常取值为 10^{-50} , 防止所在分式的分母为 0; f_i 为当前麻雀的适应度值; f_g 、 f_w 分别为当前全局最优和最差适应度值。

2 基于 ISSA-CNN-GRU 模型的充电负荷预测方法

本文考虑电动汽车充电站充电负荷的多因影响, 提出基于 ISSA-CNN-GRU 模型的充电负荷预测方法, 其原理框图如图 3 所示。

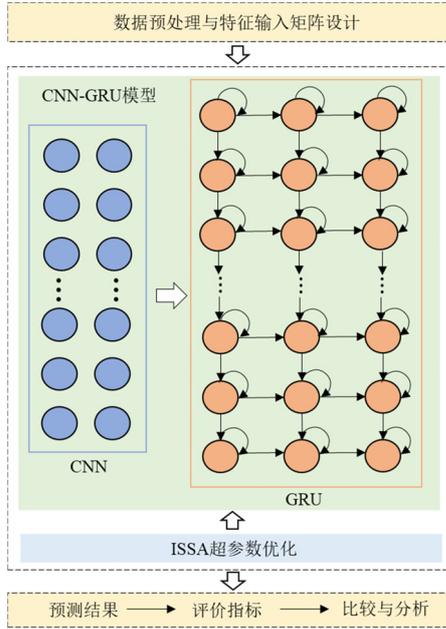


图 3 充电负荷预测方法原理图

Fig. 3 Schematic diagram of charging load prediction method

2.1 数据预处理与特征输入矩阵

用户前往充电站充电行为的随机性导致了充电站充电负荷的高不确定性, 通过分析研究数据集负荷特性, 选定日期类型(周日期)、节假日、气温 3 种电动汽车充电站充电负荷的显著影响因素与历史充电负荷共同构建输入特征矩阵。

2.1.1 数据预处理

由于所提预测方法针对充电站每小时内充电负荷进行预测, 而充电站数据采集系统导出的历史充电数据每一行对应一笔充电订单信息, 该行数据还包含如订单编号、充电桩 ID 等众多无效信息, 故使用 Python 中的 Pandas 包对数据进行筛选清洗, 每一行仅保留充电负荷与充电起止时间信息。之后将每次的负荷拆分成每天 24 h 即 24 个时刻的充电负荷。

此外, 充电站采集的原始充电负荷数据经常包含一些空值, 而充电站电动汽车充电负荷数据具有一定的周期性, 负荷数据在相似日期类型时具有较高的一致性。因此, 对于空值采用式(5)进行填充。

$$y_k = \frac{y_{k-1} + y_{k+1}}{2} \quad (5)$$

式中: y_k 为缺失时刻填充数据; y_{k-1} 为前一周的相同周日期同时刻充电负荷值; y_{k+1} 为后一周的相同周日期同时刻充电负荷值。若出现连续一段时间均为空值, 则可取前一周和后一周相同周日期的相同时间段充电负荷数据的均值进行填充。气温数据亦做相同处理。

为使网络损失函数加速收敛, 提高模型训练速度, 需对日期类型、节假日类型数据进行 One-hot 编码, 对历史负荷和气温数据进行归一化处理, 归一化公式为

$$x_{\text{one}} = \frac{x - x_{\min}}{x_{\max} - x} \quad (6)$$

式中: x 为归一化前样本数据; x_{one} 为归一化后数值; x_{\max} 和 x_{\min} 分别为归一化前样本数据中最大值和最小值。

2.1.2 模型的输入特征矩阵设计

模型的输入输出关系设计如式(7)所示。

$$\hat{w}_{k+1} = f(\mathbf{D}_{(k-m) \times 7}, \mathbf{H}_{(k-m) \times 2}, \mathbf{T}_{(k-m) \times 1}, \mathbf{w}_{(k-m) \times 1}) \quad (7)$$

式中: $\mathbf{D}_{(k-m) \times 7}$ 、 $\mathbf{H}_{(k-m) \times 2}$ 、 $\mathbf{T}_{(k-m) \times 1}$ 和 $\mathbf{w}_{(k-m) \times 1}$ 为模型输入特征量 \mathbf{X} , 分别代表日期类型(周日期)、节假日、气温和充电站历史充电负荷; \hat{w}_{k+1} 为模型输出量 \mathbf{Y} , 即充电负荷预测值; k 为当前样点时刻; $k+1$ 为待预测时刻; $k-m$ 为待预测时刻前 $m+1$ 个时刻, 包含 k 时刻。

模型的输入特征矩阵 \mathbf{X} 为

$$\mathbf{X} = [\mathbf{D}_{(m+1) \times 7}, \mathbf{H}_{(m+1) \times 2}, \mathbf{T}_{(m+1) \times 1}, \mathbf{w}_{(m+1) \times 1}] \quad (8)$$

式中: 每个训练样本 \mathbf{X} 为 $(m+1) \times 11$ 阶的矩阵; $\mathbf{D}_{(m+1) \times 7}$ 和 $\mathbf{H}_{(m+1) \times 2}$ 分别为周日期和节假日类型的 One-hot 编码矩阵, 如式(9)、式(10)所示。

$$\mathbf{D}_{(m+1) \times 7} = \begin{bmatrix} D_{11} & D_{12} & \cdots & D_{17} \\ D_{21} & D_{22} & \cdots & D_{27} \\ \vdots & \vdots & & \vdots \\ D_{(m+1)1} & D_{(m+1)2} & & D_{(m+1)7} \end{bmatrix} \quad (9)$$

$$\mathbf{H}_{(m+1) \times 2} = \begin{bmatrix} H_{11} & H_{12} \\ H_{21} & H_{22} \\ \vdots & \vdots \\ H_{(m+1)1} & H_{(m+1)2} \end{bmatrix} \quad (10)$$

式中: $D_{j1} D_{j2} D_{j3} D_{j4} D_{j5} D_{j6} D_{j7}$ ($j=1, 2, \dots, m+1$) 为 7

位二进制代码 1000000、0100000、...、0000010 或 0000001, 7 位二进制代码按序分别代表周日期中的周一至周日, 代码中某一位为 1 则代表当天的日期类型为该位对应的周日期, 如 0 010 000 代表当天日期类型为周三; $H_{i1}H_{i2}$ 为 2 位二进制代码 01 或 10, 二进制代码 01 代表当天为节假日, 二进制代码 10 代表当天为非节假日。 $T_{(m+1)\times 1}$ 和 $w_{(m+1)\times 1}$ 分别为气温和历史充电负荷序列的列向量, 如式(11)所示。

$$T_{(m+1)\times 1} = \begin{bmatrix} T_1 \\ T_2 \\ \vdots \\ T_{(m+1)} \end{bmatrix} \quad w_{(m+1)\times 1} = \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_{m+1} \end{bmatrix} \quad (11)$$

式中, T_j 和 $w_j (j=1,2,\dots,m+1)$ 分别为气温和历史负荷的十进制数值, 单位分别为 $^{\circ}\text{C}$ 和 kW 。

本文选取 $m=23$, 即待预测时刻前 24 h 历史数据构成输入特征矩阵进行未来 1 h 充电负荷预测, 因此, 模型的输入是由若干个 24×11 的输入特征矩阵组成的输入向量。

2.2 CNN-GRU 模型结构设计

结合 CNN 和 GRU 网络, 设计了 CNN-GRU 混合神经网络的充电负荷预测模型, 其结构设计为 9 层, 如图 4 所示。

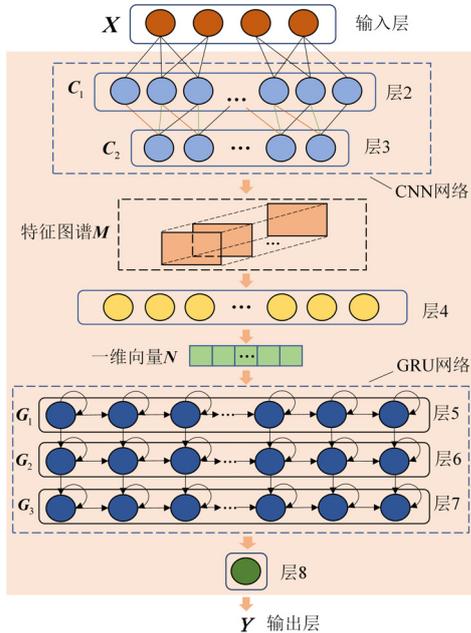


图 4 CNN-GRU 负荷预测模型结构

Fig. 4 Structure of CNN-GRU load forecasting model

图 4 中, 橙红色区域为 CNN-GRU 负荷预测模型主要结构, 其先由两层 CNN 降维提取输入数据的特征量, 再将基于降维特征量的特征图谱伸展为

一维向量输入 GRU 神经网络, 进行模型训练, 最后由一个全连接层整合 GRU 神经网络预测结果, 输出指定格式的预测值。

除了输入层和输出层, CNN-GRU 负荷预测模型的其他各层描述如下。

层 2 和层 3: 卷积块, 输入数据经其平移卷积提取特征信息, 再经激活与池化方可输出特征图谱。其中, 层 2 卷积核大小设置为 3×5 , 层 3 卷积核大小设置为 3×3 , 步长均为 1。池化为平均池化, 激活函数为 elu 函数。层 2 和层 3 的输出分别表示为式(12)和式(13)。

$$C_1 = C_{\text{NN}}(X) \quad (12)$$

$$C_2 = C_{\text{NN}}(C_1) \quad (13)$$

CNN 输出的特征图谱 M 如式(14)所示。

$$M = C_2 \quad (14)$$

层 4: 扁平层, 将特征图谱 M 的三维向量数组伸展为一维向量数组 N 。

层 5、层 6 和层 7: 3 层 GRU 层堆叠构成 GRU 网络。特征图谱 M 经扁平层转化为一维向量 N 后输入层 5。3 层 GRU 层在 l 步的输出分别表示为 $g_{1,l}$ 、 $g_{2,l}$ 、 $g_{3,l}$, 如式(15)一式(17)所示。

$$g_{1,l} = G_{\text{RU}}(g_{1,l-1}, N_l) \quad (15)$$

$$g_{2,l} = G_{\text{RU}}(g_{2,l-1}, G_{1,l}) \quad (16)$$

$$g_{3,l} = G_{\text{RU}}(g_{3,l-1}, G_{2,l}) \quad (17)$$

式中: $g_{1,l-1}$ 为层 5 在 $l-1$ 步的输出; N_l 为 l 步输入层 5 的一维向量数组; $g_{2,l-1}$ 为层 6 在 $l-1$ 步的输出; $G_{1,l}$ 为层 5 在 l 步的输出; $g_{3,l-1}$ 为层 7 在 $l-1$ 步的输出; $G_{2,l}$ 为层 6 在 l 步的输出。可见各层在 l 步的输出取决于该步的输入与前一步的输出。

层 8: 全连接层, 全连接层负责整合 G_3 中的结果, 然后输出指定格式的向量, 其神经元个数要与模型输出个数匹配。因 CNN-GRU 负荷预测模型输出为单个时刻充电负荷预测值, 故全连接层神经元个数为 1。

在训练阶段, 负荷预测模型中的权重参数通过权重更新和反向传播进行更新优化。优化完成后, 使用输入特征矩阵 X_{test} 进行测试, 得到充电负荷测试值。

2.3 基于 ISSA 算法优化 CNN-GRU 模型超参数

传统的神经网络模型超参数值的设定往往依据经验进行试凑, 根据模型性能逐步调整直至逼近最优值。然而, 依据经验的手动调优在没有深厚专业知识的支持下, 往往难以取得很好的效果, 容易出现过拟合和欠拟合现象, 且耗费时间。因此, 本文采用

ISSA 算法对所提 CNN-GRU 模型进行超参数调优。

2.3.1 ISSA 算法

1) Circle 混沌映射

原始麻雀搜索算法采用随机生成方式初始化种群, 这种方式使得初始麻雀种群存在聚集的可能, 从而导致搜索空间分布不均匀, 影响算法的寻优性能。混沌序列映射因具有随机性、遍历性和非重复性等特点, 常被用于优化搜索问题。因此, 引入 Circle 混沌映射初始化麻雀种群, 使其分布均匀^[28]。Circle 混沌映射表达式如式(18)所示。

$$x_{n+1} = \text{mod} \left(x_n + 0.2 - \left(\frac{0.5}{2\pi} \right) \sin(2\pi \cdot x_n), 1 \right) \quad (18)$$

式中: n 表示解的维度; x_n 为 Circle 混沌映射前的解; x_{n+1} 为 Circle 混沌映射后的解。

2) 樽海鞘群算法

由式(2)可知, 在 $R_2 < ST$ 时, 发现者位置的每一维都在向 0 收敛, 这使得算法在 0 附近区域搜索到最优值的可能性增加, 算法易陷入局部最优。因此, 为提高算法全局搜索能力, 协调麻雀个体全局与局部搜索能力, 借鉴樽海鞘群算法^[29]中领导者的更新策略, 其表达式如式(19)所示。

$$x_d^i = \begin{cases} F_d + c_1(u_b - l_b)c_2 + l_b, & c_3 \geq 0.5 \\ F_d - c_1(u_b - l_b)c_2 + l_b, & c_3 < 0.5 \end{cases} \quad (19)$$

式中: x_d^i 为第 i 个个体在 d 维的位置; F_d 为食源在 d 维的位置; u_b 、 l_b 分别为解的上下限值; c_2 、 c_3 均为[0,1]间的随机数; c_1 为衰减变量, 表达式如式(20)所示。

$$c_1 = 2e^{-(4t/T_{\max})^2} \quad (20)$$

式中: t 为当前迭代次数; T_{\max} 为最大迭代次数。

将发现者位置更新公式修改如式(21)所示。

$$X_i^{t+1} = \begin{cases} X_i^t \cdot \frac{[c_1(u_b - l_b)c_2 + l_b]}{u_b}, & R_2 < ST \\ X_i^t + \beta_2 \cdot L, & R_2 \geq ST \end{cases} \quad (21)$$

3) 加入者

由式(3)可知, 当 $i > Q/2$ 时, 麻雀位置等于一个标准正态分布随机数与一个自然对数为底数的指数函数的积, 种群收敛时其值收敛于 0。因此, 为保证每只加入者向其追随的发现者靠近而不陷于 0, 将式(3)修改为式(22)。

$$X_i^{t+1} = X_p^t + |X_i^t - X_p^t| \cdot L \cdot A^+ \quad (22)$$

4) 侦察者

在式(4)中, 因为 β_3 和 K 均为关于原点对称的随机数, 故将式(4)中绝对值符号修改为如式(23)

所示。

$$X_i^{t+1} = \begin{cases} X_{\text{best}}^t + \beta_3 \cdot (X_i^t - X_{\text{best}}^t), & f_i \neq f_g \\ X_i^t + K \cdot \left(\frac{X_i^t - X_{\text{worst}}^t}{|f_i - f_w| + \varepsilon} \right), & f_i = f_g \end{cases} \quad (23)$$

2.3.2 超参数优化

设置 CNN-GRU 模型中两层 CNN 层的卷积核数量、三层 GRU 层的隐藏神经元数量、最大迭代次数、批样本大小和学习率为待优化的超参数。其中两层 CNN 层的卷积核数量和三层 GRU 层的隐藏神经元数量寻优范围均为[8,128], 最大迭代次数寻优范围为[10,100], 批样本大小寻优范围为[128, 512], 学习率寻优范围为[0.001, 0.1]。使用所提 ISSA 算法和贝叶斯优化(Bayesian optimization, BO)算法、粒子群优化(particle swarm optimization, PSO)算法分别对上述超参数进行优化, 3 种优化方法均以验证集预测结果的平均平方误差(mean square error, MSE)最小为目标函数。

为了更好地在模型训练过程中进行梯度估计的修正, 模型选用可以自适应调整学习率的 Adam 算法作为模型梯度的优化算法。又因为在模型训练开始需要学习率保持大些来保证收敛速度, 在收敛到最优点附近时又要小些以避免来回振荡, 故采用学习率分段常数衰减方法。学习率衰减周期设为 20 个 Epoch, 衰减率为 0.8。此外, 为防止网络过拟合, 对 GRU 网络采用 Dropout 方法, 在训练过程中随机丢弃部分隐藏神经元以减轻过拟合现象。

2.4 评价指标

为评估本文所提预测方法的预测精度, 选取平均绝对误差(mean absolute error, MAE)和均方根误差(root mean squared error, RMSE)为评价指标。

时间序列预测常用 MAE、RMSE 和平均百分比误差(mean absolute percentage error, MAPE)评价预测精度。由于充电站历史充电负荷数据存在很多充电负荷值为 0 的时刻, 而 MAPE 的计算中需要历史充电负荷数据作分母, 故选取 MAE 和 RMSE 作为预测精度的评价指标。MAE 和 RMSE 的公式为

$$M_{\text{AE}} = \frac{1}{q} \sum_{k=1}^q (|w_k - \hat{w}_k|) \quad (24)$$

$$R_{\text{MSE}} = \sqrt{\frac{1}{q} \sum_{k=1}^q (w_k - \bar{w}_k)^2} \quad (25)$$

式中: w_k 为 k 时刻的充电负荷真实数据; \hat{w}_k 为 CNN-GRU 模型预测的 k 时刻充电负荷数据; \bar{w}_k 为充电负荷真实数据平均值; q 为测试数据集中数据点数。

3 算例分析

本文选用美国 ANN-DATA 公开数据集^[30]中一个位于加州理工大学校园内的电动汽车充电站的历史充电负荷数据进行实验,选择 RF、CNN、GRU、CNN-GRU、BO-CNN-GRU、PSO-CNN-GRU、SSA-CNN-GRU 与所提 ISSA-CNN-GRU 模型进行未来 1 h 充电负荷预测,并进行结果对比,验证所提 SSA-CNN-GRU 模型的预测方法的科学性和有效性。所有方法的输入数据及特征维度完全相同,其中所有深度学习方法的网络层数完全相同。所有模型均基于 Matlab R2020a 平台实现,平台搭载环境为 Intel i5-11260H 处理器, Nvidia-GTX-3050Ti 显卡。

3.1 数据准备

选取 2018 年 11 月 1 日至 2019 年 10 月 31 日所有 54 个充电桩的历史充电负荷数据,整理得 8760 个采样点,其中节选 2018 年 11 月原始充电负荷数据如图 5 所示,可见存在许多充电负荷为 0 的时刻。对应的每天 24 h 气温数据采用加州理工大学所在洛杉矶市历史气象数据,由美国国家海洋和大气管理局网站公开数据获得。周日期和节假日类型依据当地实情设置。

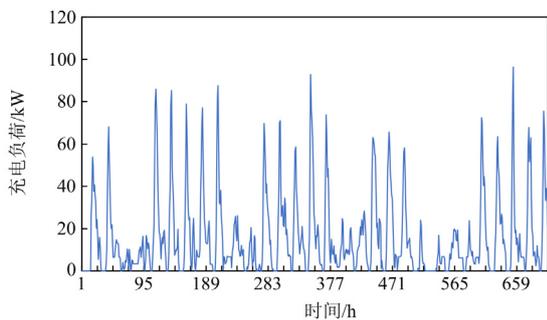


图 5 充电站原始充电负荷数据

Fig. 5 Original charging load data of charging station

所有输入数据依照 2.1 节所提方法进行预处理,预处理后的连续 24 个时刻充电负荷历史数据与对应该时刻的气温、日期类型及节假日类型特征数据共同构成特征输入矩阵。整个输入数据集按 7:1:2 的比例划分训练集、验证集和测试集。

3.2 超参数优化结果

BO、PSO、标准 SSA、ISSA 分别对 CNN-GRU 模型超参数寻优结果如表 1 所示。

3.3 实验结果对比分析

各模型分别重复 100 次训练—预测过程,预测结果的 MAE 均值、标准差与 RMSE 的对比如表 2 所示。由表 2 可见,所提 ISSA-CNN-GRU 模型具

有最小的 MAE 均值和 RMSE 均值,预测精度最高。相比于其他 7 种模型,ISSA-CNN-GRU 模型的 MAE 均值分别降低了 0.3305、0.7181、0.6687、0.3652、0.3055、0.1857、0.2236, RMSE 均值分别降低了 0.6104、0.6438、0.3702、0.2103、0.2652、0.0301、0.1961。其中 CNN-GRU 模型预测精度相比于单独的 CNN 和 GRU 模型,MAE 均值分别降低了 0.3529、0.3035, RMSE 均值分别降低了 0.4335、0.1599,证明了 CNN 与 GRU 网络的组合模型相较于单独的 CNN 和 GRU 模型在处理时间序列数据方面性能更佳。此外,相较于 CNN-GRU 模型和经 BO、PSO、标准 SSA 进行超参数调优的 CNN-GRU 模型,所提 ISSA-CNN-GRU 模型的预测精度最高,体现了所提 ISSA 寻优算法对于模型性能的显著提升作用。且由表 2 可见,ISSA-CNN-GRU 模型预测结果的 MAE 与 RMSE 的标准差均很小,说明了其预测结果的稳定性。

表 1 超参数寻优结果

寻优参数	寻优范围	BO	PSO	SSA	ISSA
卷积核个数 1	[8,128]	45	8	8	52
卷积核个数 2	[8,128]	79	8	44	31
隐藏神经元 个数 1	[8,128]	87	120	57	83
隐藏神经元 个数 2	[8,128]	124	128	67	90
隐藏神经元 个数 3	[8,128]	64	115	10	25
最大迭代次数	[10,100]	75	100	54	100
批样本大小	[128,512]	253	512	151	187
学习率	[0.001,0.1]	0.0013	0.0010	0.0041	0.0046

表 2 模型预测精度比较

预测模型	MAE	MAE	RMSE	RMSE
	均值	标准差	均值	标准差
ISSA-CNN-GRU	3.0576	0.2113	4.4872	0.1202
RF	3.3881	0.0192	5.0976	0.0282
CNN	3.7757	0.3302	5.1310	0.2091
GRU	3.7263	0.2146	4.8574	0.2044
CNN-GRU	3.4228	0.1910	4.6975	0.1252
BO-CNN-GRU	3.3631	0.2176	4.7524	0.1115
PSO-CNN-GRU	3.2433	0.1901	4.5173	0.1119
SSA-CNN-GRU	3.2812	0.3019	4.6833	0.2157

图 6 为各模型预测误差箱型图,其中 CG、BCG、PCG、SCG、ICG 分别代表 CNN-GRU、BO-

CNN-GRU、PSO-CNN-GRU、SSA-CNN-GRU、ISSA-CNN-GRU 预测模型。

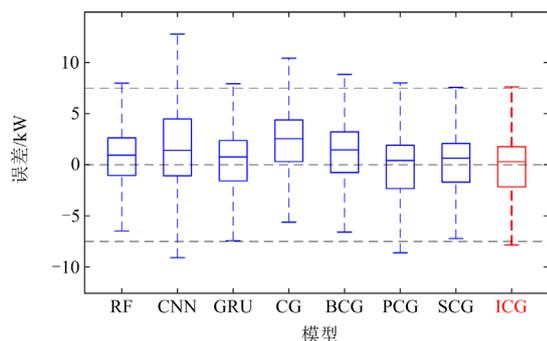


图 6 模型预测误差箱型图

Fig. 6 Box chart of model prediction errors

由图 6 可见, ISSA-CNN-GRU 模型预测结果误差对应的箱体较扁, 且误差中线最接近 0, 说明其预测结果的误差波动性最小。

对于未进行超参数调优的 4 种模型, 节选测试集中充电负荷预测结果曲线对比如图 7 所示。不同优化算法对 CNN-GRU 模型超参数调优情况下预测结果节选对比如图 8 所示。由图 7 可见, CNN 模型在充电负荷曲线剧烈转折时, 不能很好地跟随曲线的变化, 预测值误差较大; 而 GRU 模型和 CNN-GRU 模型对充电负荷的变化则有更好的跟随趋势, 其中 CNN-GRU 模型在充电负荷为 0 时的预测曲线较 GRU 模型更为贴合实际值。由图 8 可见, 不同优化算法调优的 CNN-GRU 模型都能很好地拟合出充电负荷曲线趋势, 其中 ISSA-CNN-GRU 模型的预测曲线拟合的最好, 在充电负荷最大与最小值时有着最好的跟随趋势, 尤其是在负荷为 0 时与真实负荷曲线最为贴近。可见 ISSA 算法优化超参数可有效提高 CNN-GRU 模型的预测精度。

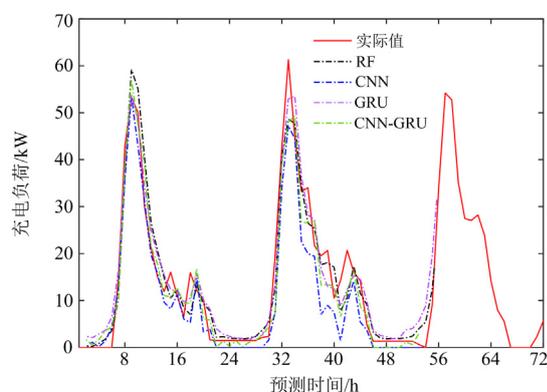


图 7 不同模型预测结果

Fig. 7 Prediction results of different models

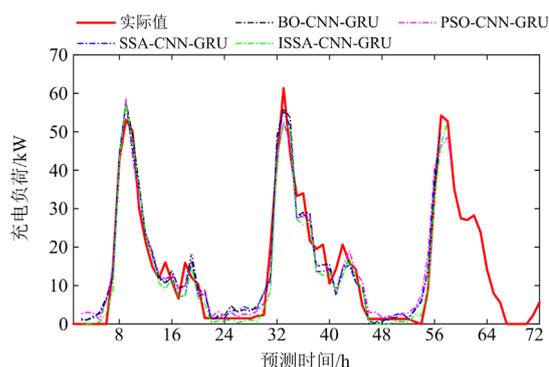


图 8 不同优化算法下 CNN-GRU 模型预测结果

Fig. 8 Prediction results of CNN-GRU model under different optimization algorithms

综合表 2、图 6—图 8 结果可得, 所提 ISSA-CNN-GRU 模型的预测精度最佳, 在电动汽车充电站短期充电负荷预测的问题上具有显著优势。

此外, 为验证所提 CNN-GRU 混合神经网络的预测能力, 选择不同网络层数的 CNN、GRU 模型对本节算例中数据集进行预测, 各模型预测结果的精度对比如表 3 所示。可见 CNN 模型随着网络层数增加, 预测精度逐渐提高, 而 GRU 模型在网络层数为两层时精度最好。但是由于 CNN 模型网络层数由两层增加到三层时, 精度提高有限, 模型训练及预测的时间却大大增加, 因此选择两层 CNN 模型与三层 GRU 模型组成 CNN-GRU 混合神经网络。

表 3 不同网络层数 CNN、GRU 模型预测精度比较

Table 3 Comparison of prediction accuracy between CNN and GRU models with different network layers

预测模型	网络层数	MAE 均值	MAE 标准差	RMSE 均值	RMSE 标准差
CNN	一层	3.8244	0.3412	5.3241	0.2210
	两层	3.7757	0.3302	5.1310	0.2091
	三层	3.7344	0.3315	4.9853	0.2103
GRU	两层	3.8261	0.2316	5.0244	0.1989
	三层	3.7263	0.2146	4.8574	0.2044
	四层	3.8608	0.2411	5.2976	0.2164

4 结论

本文立足于电动汽车充电站的短期充电负荷预测, 提出了一种基于 ISSA-CNN-GRU 模型的电动汽车充电负荷预测方法:

1) 考虑电动汽车充电站充电负荷主要影响因素, 设计了由气温、日期类型、节假日因素与历史充电负荷数据构成的 11 阶特征输入矩阵。

2) 设计搭建了以两层卷积层和三层 GRU 层为

主要结构的 CNN-GRU 模型, 将 CNN 的特征提取与数据降维特点同 GRU 神经网络对时间序列数据的处理能力巧妙结合。

3) 提出一种基于混合策略的改进麻雀搜索算法对所提 CNN-GRU 模型超参数调优, 使模型性能达到最优。

4) 算例结果表明, ISSA-CNN-GRU 预测方法与 RF、CNN、GRU、CNN-GRU 及 BO、PSO、SSA 优化的 CNN-GRU 模型相比, 预测精度最高。

综上所述, 所提基于 ISSA-CNN-GRU 模型的电动汽车充电负荷预测方法具有较高的预测精度, 具备一定工程应用价值。在接下来的研究中, 将进一步考虑天气因素中的降雨量以及电价等因素对充电站电动汽车充电负荷的影响, 构建更为全面的特征输入数据集, 进一步提高所提预测方法的预测精度。

参考文献

- [1] WANG Y, YANG Z, MOURSHED M, et al. Demand side management of plug-in electric vehicles and coordinated unit commitment: a novel parallel competitive swarm optimization method[J]. *Energy Conversion and Management*, 2019, 196: 935-949.
- [2] 余潇潇, 宋福龙, 周原冰, 等. “新基建”对中国“十四五”电力需求和电网规划的影响分析[J]. *中国电力*, 2021, 54(7): 11-17.
YU Xiaoxiao, SONG Fulong, ZHOU Yuanbing, et al. Investigations on the impact of new infrastructure on electricity forecast and power system planning during the 14th five-year plan period[J]. *Electric Power*, 2021, 54(7): 11-17.
- [3] 蔡海青, 代伟, 赵静怡, 等. 基于多参数规划的电动汽车充电站有效容量评估方法[J]. *中国电力*, 2022, 55(11): 175-183.
CAI Haiqing, DAI Wei, ZHAO Jingyi, et al. Available capacity evaluation method of electric vehicle charging stations based on multi-parametric programming[J]. *Electric Power*, 2022, 55(11): 175-183.
- [4] 张天培, 王成亮, 崔恒志, 等. 基于WNN与FCM的电动汽车动态充电负荷预测方法[J]. *电力工程技术*, 2021, 40(1): 167-174.
ZHANG Tianpei, WANG Chengliang, CUI Hengzhi, et al. Dynamic charging load prediction method of electric vehicle based on wavelet neural network and FCM[J]. *Electric Power Engineering Technology*, 2021, 40(1): 167-174.
- [5] 袁小溪, 潘鸣宇, 段大鹏, 等. 基于网格划分的电动汽车充电负荷预测方法[J]. *电力科学与技术学报*, 2021, 36(3): 19-26.
YUAN Xiaoxi, PAN Mingyu, DUAN Dapeng, et al. Prediction method of electric vehicle charging load based on grid division[J]. *Journal of Electric Power Science and Technology*, 2021, 36(3): 19-26.
- [6] 陈丽丹, 张尧, FIGUEIREDO A. 电动汽车充放电负荷预测研究综述[J]. *电力系统自动化*, 2019, 43(10): 177-191.
CHEN Lidian, ZHANG Yao, FIGUEIREDO A. Overview of charging and discharging load forecasting for electric vehicles[J]. *Automation of Electric Power Systems*, 2019, 43(10): 177-191.
- [7] CHANG X, SONG Z, WANG J. Electric vehicle charging load prediction and system development based on Monte Carlo algorithm[J]. *High Voltage Apparatus*, 2020, 56(8): 1-5.
- [8] ZHANG X, CHAN K W, LI H, et al. Deep-learning-based probabilistic forecasting of electric vehicle charging load with a novel queuing model[J]. *IEEE Transactions on Cybernetics*, 2021, 51(6): 3157-3170.
- [9] HAN X, WEI Z, HONG Z, et al. Ordered charge control considering the uncertainty of charging load of electric vehicles based on Markov chain[J]. *Renewable Energy*, 2020, 161: 419-434.
- [10] 赵书强, 周靖仁, 李志伟, 等. 基于出行链理论的电动汽车充电需求分析方法[J]. *电力自动化设备*, 2017, 37(8): 105-112.
ZHAO Shuqiang, ZHOU Jingren, LI Zhiwei, et al. EV charging demand analysis based on trip chain theory[J]. *Electric Power Automation Equipment*, 2017, 37(8): 105-112.
- [11] LIN H, FU K, WANG Y, et al. Characteristics of electric vehicle charging demand at multiple types of location-application of an agent-based trip chain model[J]. *Energy*, 2019, 188.
- [12] 张琳娟, 许长清, 王利利, 等. 基于OD矩阵的电动汽车充电负荷时空分布预测[J]. *电力系统保护与控制*, 2021, 49(20): 82-91.
ZHANG Linjuan, XU Changqing, WANG Lili, et al. OD matrix based spatiotemporal distribution of EV charging load prediction[J]. *Power System Protection and Control*, 2021, 49(20): 82-91.
- [13] 邓艺璇, 黄玉萍, 黄周春. 基于随机森林算法的电动汽车充放电容量预测[J]. *电力系统自动化*, 2021, 45(21): 181-188.
DENG Yixuan, HUANG Yuping, HUANG Zhouchun. Charging and discharging capacity forecasting of electric vehicles based on random forest algorithm[J]. *Automation of Electric Power Systems*, 2021, 45(21): 181-188.
- [14] LU K, SUN W, MA C, et al. Load forecast method of

- electric vehicle charging station using SVR based on GA-PSO[C] // 3rd International Conference on Advances in Energy, Environment and Chemical Engineering, May 26-28, 2017, Chengdu, China: 1-10.
- [15] 张维戈, 颀飞翔, 黄梅, 等. 快换式公交充电站短期负荷预测方法的研究[J]. 电力系统保护与控制, 2013, 41(4): 61-66.
ZHANG Weige, XIE Feixiang, HUANG Mei, et al. Research on short-term load forecasting methods of electric buses charging station[J]. Power System Protection and Control, 2013, 41(4): 61-66.
- [16] ZHU J, YANG Z, GUO Y, et al. Short-term load forecasting for electric vehicle charging stations based on deep learning approaches[J]. Applied Sciences-Basel, 2019, 9(9).
- [17] LI Y, HUANG Y, ZHANG M. Short-term load forecasting for electric vehicle charging station based on niche immunity lion algorithm and convolutional neural network[J]. Energies, 2018, 11(5).
- [18] FENG J, YANG J, LI Y, et al. Load forecasting of electric vehicle charging station based on grey theory and neural network[J]. Energy Reports, 2021, 7: 487-492.
- [19] 王哲, 万宝, 凌天晗, 等. 基于谱聚类和 LSTM 神经网络的电动公交车充电负荷预测方法[J]. 电力建设, 2021, 42(6): 58-66.
WANG Zhe, WAN Bao, LING Tianhan, et al. Electric bus charging load forecasting method based on spectral clustering and LSTM neural network[J]. Electric Power Construction, 2021, 42(6): 58-66.
- [20] SHI H, XU M H, LI R. Deep learning for household load forecasting-a novel pooling deep RNN[J]. IEEE Transactions on Smart Grid, 2018, 9(5): 5271-5280.
- [21] WU L Z, KONG C, HAO X H, et al. A short-term load forecasting method based on GRU-CNN hybrid neural network model[J]. Mathematical Problems in Engineering, 2020: 1428104.
- [22] 邹智, 吴铁洲, 张晓星, 等. 基于贝叶斯优化 CNN-BiGRU 混合神经网络的短期负荷预测[J]. 高电压技术, 2022, 48(10): 3935-3945.
ZOU Zhi, WU Tiezhou, ZHANG Xiaoxing, et al. Short-term load forecast based on Bayesian optimized CNN-BiGRU hybrid neural networks[J]. High Voltage Engineering, 2022, 48(10): 3935-3945.
- [23] 王雨虹, 王志中, 付华, 等. 多策略改进麻雀算法与 BiLSTM 的变压器故障诊断研究[J]. 仪器仪表学报, 2022, 43(3): 87-97.
WANG Yuhong, WANG Zhizhong, FU Hua, et al. Research on transformer fault diagnosis based on the improved multi-strategy sparrow algorithm and BiLSTM[J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 87-97.
- [24] 任建吉, 位慧慧, 邹卓霖, 等. 基于 CNN-BiLSTM-Attention 的超短期电力负荷预测[J]. 电力系统保护与控制, 2022, 50(8): 108-116.
REN Jianji, WEI Huihui, ZOU Zhuolin, et al. Ultra-short-term power load forecasting based on CNN-BiLSTM-Attention[J]. Power System Protection and Control, 2022 50(8): 108-116.
- [25] SHAN Cheng, ZIHAO Yu, YE Liu, et al. Power system transient stability assessment based on the multiple paralleled convolutional neural network and gated recurrent unit[J]. Protection and Control of Modern Power Systems, 2022, 7(3): 586-601.
- [26] 陈梓行, 金涛, 郑熙东, 等. 基于新型日期映射法和 ISGU 混合模型的短期电力负荷预测[J]. 电力系统保护与控制, 2022, 50(15): 72-80.
CHEN Zixing, JIN Tao, ZHENG Xidong, et al. Short-term power load forecasting based on a new date mapping method and an ISGU hybrid model[J]. Power System Protection and Control, 2022, 50(15): 72-80.
- [27] XUE J K, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [28] ARORA S, ANAND P. Chaotic grasshopper optimization algorithm for global optimization[J]. Neural Computing and Applications, 2019, 31(8): 4385-4405.
- [29] MIRJALILI S, GANDOMI A H, MIRJALILI S Z, et al. Salp swarm algorithm: a bio-inspired optimizer for engineering design problems[J]. Advances in Engineering Software, 2017, 114: 163-191.
- [30] ZACHARY J. L, LI Tongxin, STEVEN H. L. ACN-Data: analysis and applications of an open EV charging dataset[C] // Proceedings of Proceedings of the Tenth ACM International Conference on Future Energy Systems, June 25-28, 2019, Phoenix, AZ, USA: 1-11.

收稿日期: 2023-01-14; 修回日期: 2023-05-18

作者简介:

姚芳(1972—), 女, 博士, 教授, 主要研究方向为电工装备可靠性; E-mail: yaofang@hebut.edu.cn

汤俊豪(1997—), 男, 硕士研究生, 主要研究方向为智慧能源系统。E-mail: m18235130267@163.com

(编辑 张颖)