

引用格式:张菲菲,张金荣,鲁涛,等.基于数据驱动的分布式低碳能源站状态预测方法[J].电力科学与技术学报,2024,39(2):231-239.

Citation: ZHANG Feifei, ZHANG Jinrong, LU Tao, et al. A data-driven method for state prediction of distributed low-carbon energy stations[J]. Journal of Electric Power Science and Technology, 2024, 39(2): 231-239.

# 基于数据驱动的分布式低碳能源站状态预测方法

张菲菲<sup>1</sup>, 张金荣<sup>1</sup>, 鲁涛<sup>1</sup>, 赵睿智<sup>1</sup>, 王加祥<sup>1</sup>, 罗涌恒<sup>2</sup>, 姜飞<sup>2</sup>

(1. 国网上海市电力公司长兴供电公司, 上海 201913; 2. 长沙理工大学电气与信息工程学院, 湖南长沙 410114)

**摘要:** 分布式低碳能源站 (distributed low-carbon energy station, DLCES) 能提高能源利用效率和可再生能源消纳率, 准确预测 DLCES 的未来运行状态能保障其安全可靠运行。为此, 提出一种基于数据驱动的分布式低碳能源站状态预测方法。首先, 分析 DLCES 结构与运行状态, 利用关键状态量和偏移量变化将运行状态划分为正常、恢复、临界及紧急状态; 其次, 构建深度长短期记忆 (long-short term memory, LSTM) 模型, 并利用改进粒子群算法进行超参数优化, 提升预测模型性能; 最后, 利用测试集数据对柯西变异的粒子群算法 (Cauchy mutation particle swarm optimization, CMPSO) 和 LSTM 相结合的模型进行预测仿真, 将其与 RNN、LSTM 及 BP 神经网络预测结果对比分析。结果表明: CMPSO-LSTM 模型能提高预测效果, 更具实际意义。

**关键词:** 状态预测; 长短期记忆模型; 柯西变异的粒子群算法; 时序预测

DOI: 10.19781/j.issn.1673-9140.2024.02.026 中图分类号: TM863 文章编号: 1673-9140(2024)02-0231-09

## A data-driven method for state prediction of distributed low-carbon energy stations

ZHANG Feifei<sup>1</sup>, ZHANG Jinrong<sup>1</sup>, LU Tao<sup>1</sup>, ZHAO Ruizhi<sup>1</sup>,  
WANG Jiexiang<sup>1</sup>, LUO Yongheng<sup>2</sup>, JIANG Fei<sup>2</sup>

(1. Changxing Power Supply Company, State Grid Shanghai Electric Power Company, Shanghai 201913, China; 2. School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha 410114, China)

**Abstract:** Distributed low-carbon energy stations (DLCES) can improve energy utilization efficiency and renewable energy consumption rates. Accurate prediction of the future operating status of DLCES can ensure its safe and reliable operation. Therefore, a data-driven prediction method for the status of DLCES is proposed. Firstly, the structure and operating status of DLCES are analyzed, and the operating status is divided into normal, recovery, critical, and emergency states using key state variables and deviations. Secondly, a deep long-short term memory (LSTM) model is constructed, and an improved particle swarm optimization algorithm is used for hyper-parameter optimization to improve the performance of the prediction model. Finally, the CMPSO-LSTM model is simulated using test sets data, and the results are compared with those of RNN, LSTM, and BP neural networks. The results show that the CMPSO-LSTM model can improve prediction results and has more practical significance.

**Key words:** state prediction; long-short term memory (LSTM); Cauchy mutation particle swarm optimization (CMPSO); time series prediction

近年来,随着“碳达峰碳中和”目标持续推进,节能减排、低碳高效的发展理念成为能源领域的共识<sup>[1]</sup>。在高效能源利用和低碳环保的双重作用下,以原有气网和电网为基础的分布式低碳能源站 (distributed low-carbon energy station, DLCES) 成

为解决问题的重要方向。DLCES 通过耦合电网、气网、热网等能源网络,实现多能互补和能源高效利用,提高能源利用率和可再生能源消纳率,成为未来解决能源和环境危机的重要方式。但 DLCES 具有能源网络众多、能源设备复杂以及能源供应多

收稿日期: 2022-09-20; 修回日期: 2022-11-07

基金项目: 国网上海市电力公司科技项目 (5209KZ21N005)

通信作者: 罗涌恒 (1997—), 男, 硕士研究生, 主要从事综合能源系统优化研究; E-mail: 1873096384@qq.com

元等特点,使得准确把握 DLCES 的未来运行状态变得困难。依据历史数据与实时状态,可预测 DLCES 未来运行趋势,为运行与检修人员及时发现薄弱环节与系统安全问题提供技术支持,能为 DLCES 的实际运行起到指导作用。

状态预测在诸多领域中已有应用,国内外专家对状态预测已开展大量研究与探索。文献[2]针对核电站运行状态监测的问题,提出基于差分自回归移动平均(autoregressive integrated moving average, ARIMA)模型和长短期记忆(long-short term memory, LSTM)神经网络组合模型,对主部件的温度和流量进行单步或多步状态预测;文献[3]为充分了解变压器的绝缘老化状态,确定极化和去极化电流的关键影响因素,运用鸡群算法(Chicken swarm optimization, CSO)对 BP(back propagation)神经网络<sup>[4-5]</sup>进行优化,实现对变压器油纸绝缘状态的预测;文献[6]针对工业循环水系统的运行状态预测问题,提出基于 Dropout 层改进的卷积神经网络(convolutional neural networks, CNN)模型,有较好的预测效果;文献[7]为解决机床状态动态预测适应度差和准确度不够的情况,提出基于自适应学习的机床状态预测模型。

虽然状态预测在其他领域中得到了应用,且有较好的效果,但在综合能源系统的场景下,应用较少且主要集中于储能电池健康状态预测方面。文献[8-9]通过找出电池健康特征相关性较高的因素,运用高斯过程回归(gaussian process regression, GPR)方法建立电池老化数据驱动模型,利用数据驱动和经验模型实现对电池的健康状态预测;文献[10-11]为适应大规模的风电接入,并为风电并网提供运行保障,将历史风速等关键信息进行分类划分,运用变分模态分解(variational mode decomposition, VMD)和门控循环单元(gated recurrent unit, GRU)神经网络的组合风电功率预测模型(VMD-GRU)对风电短期的功率进行状态预测;文献[12-13]为解决电动汽车充电的状态预测问题,将电动汽车的充电进行网格划分处理,通过贝叶斯正则化优化 BP 神经网络,以最终预测不含充电设施网格的充电需求。

上述相关研究针对状态预测方面均有创新之处,但现阶段研究大多集中于电网系统中部分重要设备,对分布式低碳能源站的未来状态预测涉及较少。同时,针对状态预测方面,大多进行定量的具体数据预测,对整体未来状态定性预测较少。基于

此,提出基于数据驱动的分布式低碳能源站状态预测方法,利用柯西变异对平均最好位置粒子群算法进行改进,进而优化 LSTM 神经网络,实现对 DLCES 未来运行状态的预测。

## 1 DLCES 结构与运行状态

DLCES 建设主要目的是考虑各分立的传统能源网络、多元化能源供应源和多样化能源需求,实现各能量流相互耦合与协同。同时, DLCES 可结合当地的实际情况,对风、光等可再生能源充分利用,提高能源的自给率与系统的能源利用率,达到系统运行低碳化、高效化和经济化<sup>[14]</sup>。

### 1.1 DLCES 典型结构

DLCES 作为综合能源系统的核心,其集合了多种能源耦合设备,涉及能源的转换、分配、储存等多个环节。典型 DLCES 的结构如图 1 所示。

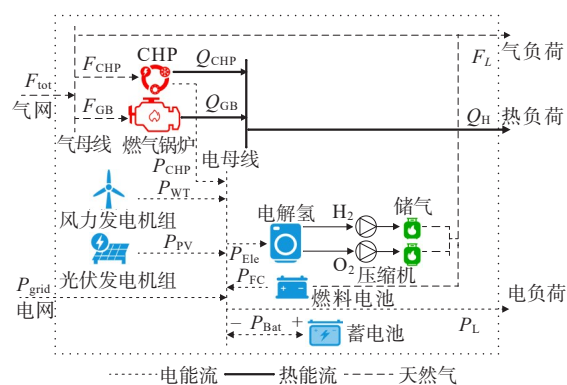


图 1 DLCES 典型结构

Figure 1 Typical structure of distributed low-carbon energy station

DLCES 主要设备有风力发电机组、光伏发电(机组)、燃气锅炉、蓄电池、电制氢(装置)以及燃料电池等。分布式低碳能源站可实现对可再生能源的优化利用,利用风能与太阳能的互补特性,削弱风力发电的反负荷特性。DLCES 中负荷包括电、气、热 3 种负荷。电负荷由风力发电机组、光伏发电(机组)、燃料电池、储能电池、上级电网和热电联产(combined heat and power, CHP)经电母线供应;气负荷由上级气网、电制氢(装置)经气母线供应;热负荷由燃气锅炉与 CHP 经热母线进行供应,其中热能主供应设备为 CHP,燃气锅炉(gas-fired boiler, GB)作为备用设备。

### 1.2 DLCES 的运行状态分析

DLCES 的关键状态量和关键状态偏移量与运行状态有直接映射关系,其运行状态取决于关键状

态量是否超过阈值和状态偏移量变化程度。状态偏移量为

$$d_i = \left| \frac{S_i - S_{iN}}{S_{iN}} \right| \times 100\% \quad (1)$$

式中,  $i$  为 e、g、h, 分别表示电、气和热网;  $S_i$  为实时状态量;  $S_{iN}$  为该状态量的额定值。

对于包含电、气和热网的 DLCES, 其关键状态量包括电网电压、热网温度和气网气压。由于关键状态量和关键状态量偏移变化与运行状态紧密相关, 故将运行状态分为正常、恢复、临界和紧急 4 种状态<sup>[15]</sup>, 如图 2 所示。

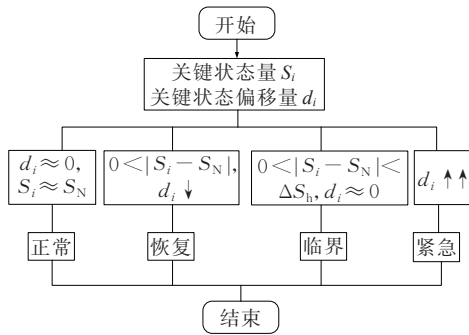


图 2 运行状态分类流程

Figure 2 Flowchart of operation status classification

系统处在正常状态时关键状态量在额定值附近波动, 关键状态偏移量极小。系统处在恢复状态时关键状态量已偏离额定值, 但关键状态偏移量在不断减少, 系统正由紧急或临界状态向正常状态转

变。系统处在临界状态时关键状态量已偏离额定值, 但还未超过或低于临界值, 关键状态偏移量变化较小。系统处在紧急状态时关键状态量已严重偏离额定值, 关键状态偏移量不断增大, 此时已发生严重故障, 无法自行恢复。

## 2 基于 LSTM 的时序深度学习模型

在进行 DLCES 的健康状态预测时, 其未来运行状态与现在状态量和状态变化量具有时序关联性。LSTM 具有优秀的记忆结构, 能很好地反映状态量数据在时间上的规律。因此, 可将其应用于 DLCES 的健康状态预测。

### 2.1 LSTM 模型

在处理长时序数据时, LSTM 针对循环神经网络 (rerrent neural network, RNN)<sup>[16]</sup> 出现的梯度爆炸和梯度消失问题进行神经细胞元的结构改进。LSTM 核心思想是, 在循环神经基础上加入遗忘门和细胞状态的结构, 使其模型在较长时间里同时具有记忆和遗忘的特性, 很好地解决了梯度爆炸和梯度消失问题, 可灵活处理长序列的时序数据。相较 RNN 区别在于 LSTM 中神经细胞具有门控制记忆单元, 网络结构如图 3 所示<sup>[2]</sup>, 其中  $C_{t-1}$  为前一时刻神经细胞状态,  $C_t$  为本时刻神经细胞状态,  $\tilde{C}_t$  为待定神经细胞状态,  $x_{t-1}$  为前一时刻输入,  $f_t$  为遗忘门输出,  $i_t$  为输入门输出,  $O_t$  为输出门输出,  $h_t$  为本时刻输出。

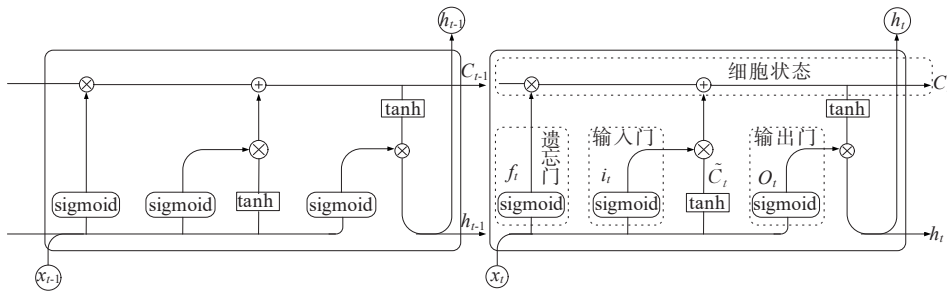


图 3 LSTM 神经细胞结构

Figure 3 Structure of LSTM neural cell

LSTM 神经细胞间信息存在前馈传递性, 能在后续状态下有选择性地记忆之前状态信息, 结合新状态下输入的信息可得到最后的输出结果。在每个 LSTM 神经细胞中, 利用输出门、输入门和遗忘门对信息进行控制。遗忘门控制对前一时刻输出信息的保留或删除, 利用 sigmoid 产生权值, 该权值为 0~1, 即完全遗忘和完全保留之间, 权值函数为

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

式中,  $W_f$  为遗忘门权值;  $b_f$  为遗忘门偏置;  $h_{t-1}$  为前一时刻输出;  $x_t$  为本时刻输入;  $\sigma$  为 sigmoid 函数, 其表达式为

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

式中,  $x$  为输入。

输入门主要作用是 LSTM 神经细胞状态的更新, 其控制输入的新信息合并到神经细胞间状态的

权重,利用sigmoid产生权重。该权值为0~1,即完全不合并和完全合并之间,权值函数为

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (4)$$

式中,  $W_i$  为输入门权值;  $b_i$  为输入门偏置。

LSTM 神经细胞中  $\tilde{C}_t$  为待定细胞状态,其表达式为

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (5)$$

式中,  $W_c$  为激活函数权值;  $b_c$  为激活函数偏置;  $\tanh$  函数将输入该函数的信号进行处理,归一化到  $[-1, 1]$ ,其表达式为

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (6)$$

根据输入门和遗忘门的输出结果,对 LSTM 神经细胞状态进行更新,其表达式为

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (7)$$

利用最后输出门和  $\tanh$  层输出结果产生细胞输出,其表达式为

$$h_t = O_t \tanh(C_t) \quad (8)$$

$$O_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (9)$$

式中,  $W_o$  为输出门权值;  $b_o$  为输出门偏置。

## 2.2 LSTM 模型预测流程

将深度 LSTM 应用于 DLCES 的状态预测中,其关键问题在于状态量信息的预处理和构建 LSTM 网络结果。针对本文所提 DLCES 的状态预测方法,主要流程如下。

1) 确定 LSTM 模型的输入和输出,为利用模型的训练和预测,需要对数据进行预处理,具体公式为

$$x'_i = \frac{x_i - \bar{x}}{\sqrt{\frac{1}{n-1} \sum (x_i - \bar{x})^2}} \quad (10)$$

其中,  $\bar{x}$  为数据平均值。对已处理后的数据集进行划分,文中采用前 80% 数据为训练集,后 20% 数据为测试集。

2) 构建 LSTM 的状态预测模型。LSTM 的网络结构如图 4 所示,其由一个输出层、一个输入层和多个隐藏层组成。首先,由输入层提取数据特征,再将其放入隐藏层;其次,隐藏层对其进行特征的分析 and 提取,隐藏层可以由多层结构组成,同时,为增强模型的泛化能力,防止模型出现过拟合,可在隐藏层增加 Dropout 层;最后,将隐藏层输出输入输出层,经过线性变换后可得到最终预测数据。

3) 测试模型的预测精度。利用测试数据对已训练模型进行预测结果比较。目前,关于分类结果

的评价主要是依据真负(true negatives, TN)、真正(true positives, TP)、假正(false positives, FP)和假负(false negatives, FN)4类结果来判断模型预测性能,本文通过混淆矩阵和召回率(average recall, AR)来判断模型的预测结果,即

$$T_{AR} = \frac{T_P + T_N}{T_P + T_N + F_P + F_N} \times 100\% \quad (11)$$

式中,  $T_{AR}$  表示召回率;  $T_P$  表示本身为正,预测为正;  $T_N$  表示本身为负,预测为负;  $F_P$  表示本身为负,预测为正;  $F_N$  表示本身为正,判断为负。

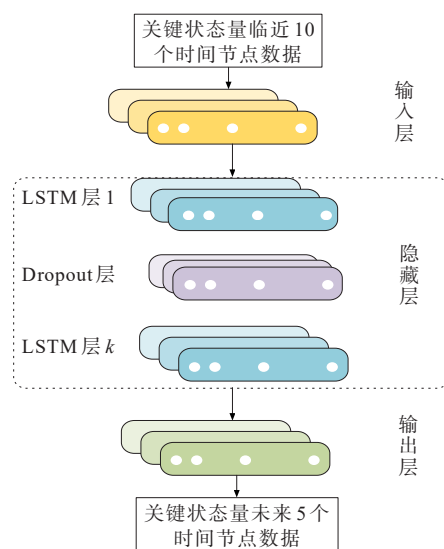


图 4 LSTM 网络结构

Figure 4 Structure of LSTM network

## 3 基于 CMPSO 的超参数优化

在 LSTM 时序神经网络训练过程中,模型超参数影响着模型的拟合状态和预测准确度。针对学习率、隐藏层层数、隐藏层细胞数和迭代次数 4 个超参数,对 LSTM 时序神经网络模型结构进行优化。模型神经细胞的学习率是重要的超参数,其直接影响神经网络的收敛性,较大的神经细胞学习率会造成模型梯度不能收敛,较小的神经细胞学习率会造成模型收敛时间较长。隐藏层的层数和神经细胞数量决定 LSTM 模型学习的深度和数据特征提取程度,过多或过少的隐藏层数量会使训练模型出现过拟合或欠拟合的情况,即模型过于精确或过于简单,使得预测结果较不准确。迭代次数过小模型训练不精确,迭代次数过大影响训练时间。

为克服单一 LSTM 神经网络模型泛化性不高、训练时间较长和处理多数据能力不足的问题<sup>[17]</sup>,采用柯西变异的粒子群算法(Cauchy mutation particle

swarm optimization, CMPSO)对超参数进行优化,以提高状态预测模型的效果与性能。

### 3.1 基于柯西变异的改进粒子群算法

在传统粒子群算法进行寻优过程中,会出现早熟的问题,使算法陷入局部最优解。算法的全局和局部寻优能力受到惯性权重的影响。惯性权重设置越大时全局寻优能力也越强;惯性权重设置越小时局部探索能力越强。在求解目标函数过程中,适应度越小时说明该粒子最优解越近,此时应该加强局部搜索能力,使得惯性权重减少;适应度越小时说明该粒子最优解越远,此时应该加强全局寻优能力,惯性权重应增加。同时,学习因子有着与惯性权重相同的特性,基于此思想,对传统粒子群算法进行改进,使得算法不易陷入局部最优解。对惯性权重和学习因子进行改进,即当 $f_i^d \geq f_{av}^d$ 或 $f_i^d < f_{av}^d$ 时,分别有

$$\omega_i^{d+1} = \omega_{\min} + (\omega_{\max} - \omega_{\min}) \cdot \frac{f_{\max}^d - f_i^d}{f_{\max}^d - f_{av}^d} \quad (12)$$

$$\begin{cases} \omega_i^{d+1} = \omega_{\max} \\ c_1 = (c_{1h} - c_{1l}) \cdot \frac{d}{d_{\max}} + c_{1l} \\ c_2 = (c_{2h} - c_{2l}) \cdot \frac{d}{d_{\max}} + c_{2l} \end{cases} \quad (13)$$

式(12)、(13)中, $\omega_i^{d+1}$ 为下一次迭代的惯性权重; $\omega_{\min}$ 、 $\omega_{\max}$ 分别为最小、最大惯性权重,取0.4、0.9; $f_{\max}^d$ 为第 $d$ 次迭代所有粒子中最大适应度; $f_i^d$ 为第 $d$ 次迭代第 $i$ 个粒子的适应度; $f_{av}^d$ 为第 $d$ 次迭代所有粒子适应度的平均值; $c_{1l}$ 和 $c_{2l}$ 、 $c_{1h}$ 和 $c_{2h}$ 分别为学习因子1、2的初、终值。

由于惯性权重和学习因子根据自适应准则不断改变,在算法运算后期会导致各粒子相互聚集,使得种群粒子的多样性缺失,因此,引入柯西变异使得种群粒子多样性增加,以获得很多的搜索信息,提升优化算法的搜索性能。当粒子迭代超过一定次数后,对部分粒子位置进行变异,即

$$\begin{cases} x' = x, & \rho > 0.5 \\ x' = x(1 + D(a)), & \rho \leq 0.5 \end{cases} \quad (14)$$

式中, $x'$ 为经柯西变异后的粒子位置; $D(a)$ 为柯西分布的随机分量。其概率密度函数为

$$f(a) = \frac{1}{\pi} \cdot \frac{a_0}{a^2_0 + a^2}, \quad -\infty < a < +\infty \quad (15)$$

### 3.2 CMPSO-LSTM 预测模型

在对传统粒子群算法进行改进后,以测试集的

均方根误差(root mean square error, RMSE)作为目标函数,以学习率、隐藏层层数、隐藏层细胞数和迭代次数4个超参数作为寻优参数,算法具体流程如图5所示。

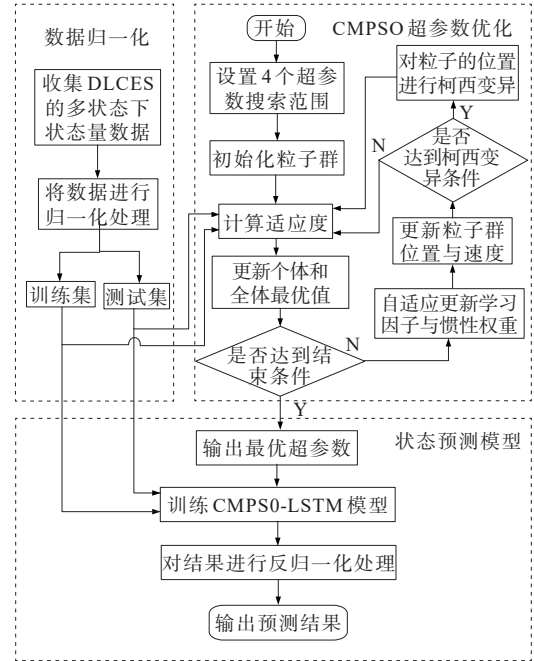


图 5 CMPSO-PSO 算法流程

Figure 5 Flowchart of CMPSO-PSO algorithm

## 4 算例分析

本文关键状态量数据来自某分布式低碳能源站,采集包含正常、临界、紧急和恢复4个状态的关键状态量数据。通过蒙特卡洛模型模拟2000组样本数据,训练集与测试集比例为8:2,基于该数据对本文所提方法进行分析。仿真实验基于PC机,CPU为AMD Ryzen 7 4700U with Radeon Graphics @4.00 GHz,内存为16 GB。LSTM与CMPSO均在MATLAB中进行搭建。

### 4.1 超参数优化

在利用CMPSO对DLCES的超参数进行优化时,需要先设置各超参数的搜索范围。依据相关研究<sup>[18-22]</sup>,本文超参数设置范围:LSTM层数、神经元个数、迭代次数、学习率分别设置为[1, 3]、[0, 300]、[0, 300]、[0.001, 0.01]。经CMPSO优化后得到最优参数为LSTM层(1层),神经元个数为260,迭代次数为246,其学习率为0.01。最优参数下LSTM模型训练过程中损失函数loss和均方根误差RMSE的变化如图6所示。




图6 损失和RMSE函数变化

Figure 6 Variation diagram of particle optimal fitness

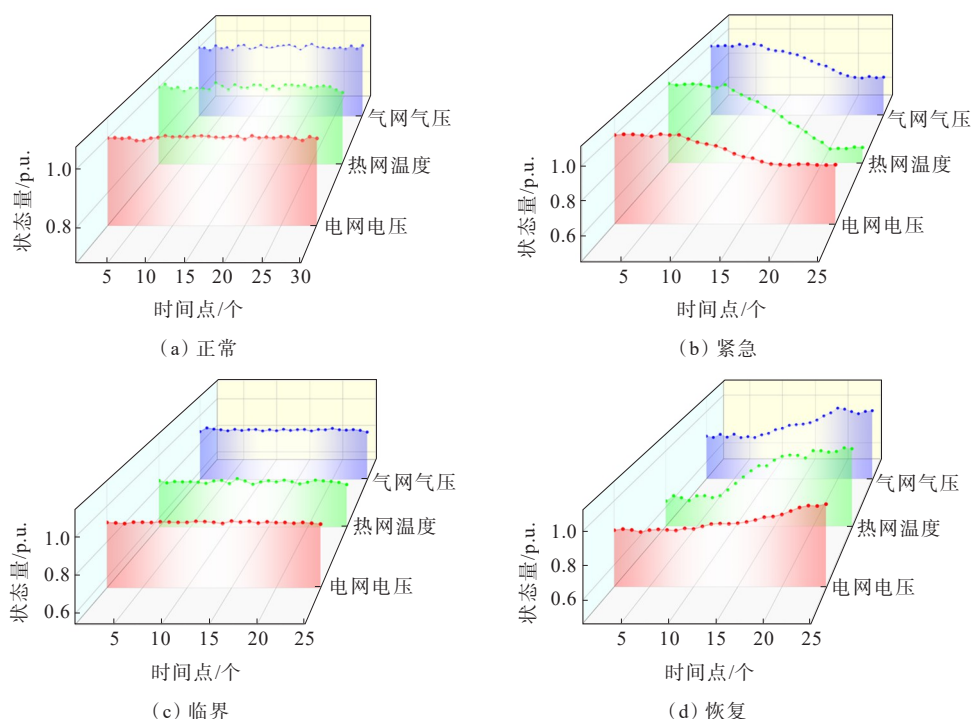


图7 各状态下预测结果

Figure 7 Prediction results of each state

由图7(a)可知,关键状态量均在额定值附近变化,有小幅波动,状态偏移量基本保持不变,其预测结果符合正常情况下关键状态量和状态偏移量变化规律。图7(b)中关键状态量变化量较大,变化速率较快,且状态偏移量不断增大,其预测结果符合紧急情况下关键状态量和状态偏移量变化规律。图7(c)中临界状态下关键状态量已大量偏移额定值,但其状态偏移量变化不大,其预测结果符合临界情况下关键状态量和状态偏移量变化规律。图7(d)中关键状态量虽已偏移额定值,但其状态偏移量在不断缩小中,系统将趋于稳定,其预测结果符合恢复情况下关键状态量和状态偏移量变化规律。由上述分析,CMP SO-LSTM模型能够较好地预测关键状态量的变化和运行状态,运行状态特征均符

## 4.2 预测结果与分析对比

将测试集中4类运行状态分别取一组数据,对已训练完成的CMP SO-LSTM模型进行状态预测。在输入前10个时间点的关键状态量数据后,预测后5个时间点的关键状态量数据。通过不断更新输入10个时间节点数据,可预测得到运行状态量未来 $5n$ 个节点数据。结合已知和预测数据,判断数据趋势,进而预测未来运行状态,最后可得到各状态预测,如图7所示。

合预期。

为验证CMP SO-LSTM相较其他预测模型的优越性,将其与LSTM、BP神经网络和RNN模型进行比较,4种方法对测试集的预测结果如图8所示,可知CMP SO-LSTM、LSTM、BP神经网络和RNN模型对各运行状态预测的正确组数分别为98、97、96、95、92、90、91、88、86、90、80、85和90、92、88、90组。

进一步分析4种不同方法预测结果,在实际正常情况下,4种模型分别出现了2、8、14、10组的紧急状态的误判。这是由于在实际数据中,正常状态下状态量数据会进行随机变动,且变动不遵循单一规律。若因客观原因出现稍大的波动与数据的随机性叠加后,可能会加大波动的幅度,进而影响预测

模型对未来趋势的预测。在实际恢复情况下,4种模型出现了3、10、10、8组的误判。这是由于在恢复状态时,可能出现由临界状态向恢复状态转变的情况,若一开始状态量变化较小或出现向负方向的波动,则会导致预测模型可能出现临界状态和紧急状态的误判。在实际临界情况下,4种模型出现了4、9、20、12组误判。这是因为该情况下关键状态量可能会随机出现向上或向下的波动,使得预测模型出现恢复状态和紧急状态的误判。在实际紧急的情况,4种模型出现了5、12、15、10组误判。这是因为关键状态量可能出现向上的波动,导致状态量数据出现开始变化不明显但随后下降较快的情况,从而出现正常状态的误判。若从临界状态至紧急状态

变化,则可能出现向上波动,导致出现临界状态或恢复状态的误判。

对于数据随机性而产生的误判,要求预测模型有较好的预测性能以克服这种偏差。根据式(11)可求得各模型的预测准确率,如表1所示,LSTM模型因为超参数设置的原因,导致模型预测达到最优的准确率为90.25%;BP神经网络预测结果相对表现较弱,准确率为85.24%;同时,虽然RNN与CMPSO-LSTM模型一样具有时序数据处理能力,但RNN因结构问题不适合作为长时间序列数据预测模型,准确率为90%。因此,CMPSO-LSTM相较LSTM、BP神经网络和RNN模型,有较好的性能,预测准确率分别提升6.25%、11.26%、6.50%。

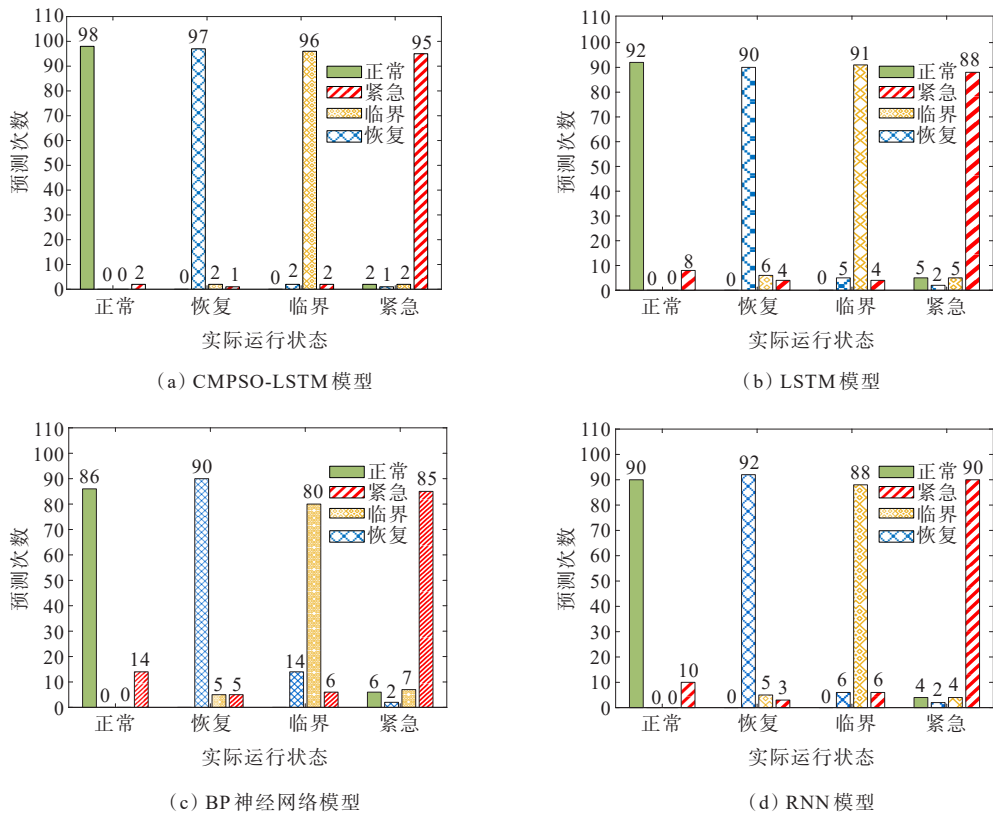


图8 4种不同方法预测结果对比

Figure 8 Prediction results of four different methods

表1 4种预测方法准确率

Table 1 Accuracy results of four prediction methods

方法	准确率/%	方法	准确率/%
CMPSO-LSTM	96.50	RNN	90.00
LSTM	90.25	BP神经网络	85.24

### 4 结语

本文针对 DLCES 运行状态预测问题,提出了

基于数据驱动的 CMPSO-LSTM 的状态预测方法。首先,根据系统关键状态量和关键状态偏移量变化将系统运行状态划分正常、恢复、临界和紧急4类运行状态;然后,构建包括输出层、输入层和隐含层的深度 LSTM 模型,运用 CMPSO 对 LSTM 状态预测模型进行优化;最后,训练 CMPSO-LSTM 模型,对其进行实例验证。

1) 利用自适应思想和柯西变异对传统粒子群

算法进行改进,形成CMPSO优化模型,利用该模型对深度LSTM模型进行超参数优化,提高LSTM模型预测性能。

2) CMPSO-LSTM能实现对DLCES未来运行状态的预测,预测结果符合各状态下关键状态量的特征,其对比LSTM、BP神经网络和RNN模型,预测准确率分别提高6.25%、11.25%、6.50%。

本文所提方法能实现对DLCES运行状态的预测,仅运行深度学习理论实现预测,并未深层次对其状态量和状态量变化与未来运行状态关系机理进行研究,未来可从深层机理的角度进行研究。

#### 参考文献:

- [1] 邓杰,姜飞,王文辉,等.考虑电热柔性负荷与氢能精细化建模的综合能源系统低碳运行[J].电网技术,2022,46(5):1692-1704.  
DENG Jie,JIANG Fei,WANG Wenye,et al.Low-carbon optimized operation of integrated energy system considering electric-heat flexible load and hydrogen energy refined modeling[J].Power System Technology,2022,46(5):1692-1704.
- [2] 朱少民,夏虹,吕新知,等.基于ARIMA和LSTM组合模型的核电厂主泵状态预测[J].核动力工程,2022,43(2):246-253.  
ZHU Shaomin,Xia Hong,LÜ Xinzhi,et al.Condition prediction of reactor coolant pump in nuclear power plants based on the combination of ARIMA and LSTM [J].Nuclear Power Engineering,2022,43(2):246-253.
- [3] 袁佳波,徐鹏程,李磊,等.基于鸡群优化BP神经网络的变压器油纸绝缘老化预测方法[J].电力科学与技术学报,2020,35(4):33-41.  
YUAN Jiabo,XU Pengcheng,LI Lei,et al.Prediction of transformer oil-paper insulation aging based on BP neural networks with the chicken swarm optimization algorithm[J].Journal of Electric Power Science and Technology,2020,35(4):33-41.
- [4] 黄星知,杨奕纯,杨兰,等.基于BP神经网络的配电网窃电降线损研究[J].电力科学与技术学报,2019,34(4):143-147.  
HUANG Xingzhi,YANG Yichun,YANG Lan,et al.Study of anti-power theft and line loss reduction for power distribution network based on BP neural network[J].Journal of Electric Power Science and Technology,2019,34(4):143-147.
- [5] 周思思,李勇,郭钺秀,等.考虑时序特征提取与双重注意力融合的TCN超短期负荷预测[J].电力系统自动化,2023,47(18):193-205.  
ZHOU Sisi,LI Yong,GUO Yixiu,et al.Ultra-short-term load forecasting based on temporal convolutional network considering temporal feature extraction and dual attention fusion[J].Automation of Electric Power Systems,2023,47(18):193-205.
- [6] 刘钢,李晓东,金轶群,等.基于深度卷积神经网络的工业循环冷却水系统运行状态预测[J].热力发电,2022,51(8):149-153.  
LIU Gang,LI Xiaodong,JIN Yiqun,et al.Operation state prediction for industrial circulating cooling water system based on deep convolutional neural network[J].Thermal Power Generation,2022,51(8):149-153.
- [7] 杜柳青,李祥,余永维.基于自适应深度学习的数控机床运行状态预测方法[J].农业机械学报,2022,53(1):451-458.  
DU Liuqing,LI Xiang,YU Yongwei,et al.Motion state prediction method of CNC machine tools based on adaptive deep learning[J].Transactions of the Chinese Society for Agricultural Machinery,2022,53(1):451-458.
- [8] 王萍,弓清瑞,张吉昂,等.一种基于数据驱动与经验模型组合的锂电池在线健康状态预测方法[J].电工技术学报,2021,36(24):5201-5212.  
WANG Ping,GONG Qingrui,ZHANG Jianguo,et al.Based on Combination of Data-Driven and Empirical Model[J].Transactions of China Electrotechnical Society,2021,36(24):5201-5212.
- [9] 顾菊平,蒋凌,张新松,等.基于特征提取的锂离子电池健康状态评估及影响因素分析[J].电工技术学报,2023,38(19):5330-5342.  
GU Juping,JIANG Ling,ZHANG Xinsong,et al.Estimation and influencing factor analysis of lithium-ion batteries state of health based on features extraction[J].Transactions of China Electrotechnical Society,2023,38(19):5330-5342.
- [10] 王鑫,李慧,叶林,等.考虑风速波动特性的VMD-GRU短期风电功率预测[J].电力科学与技术学报,2021,36(4):20-28.  
WANG Xin,LI Hui,YE Lin,et al.VMD-GRU based short term wind power forecast considering wind speed fluctuation characteristics[J].Journal of Electric Power Science and Technology,2021,36(4):20-28.
- [11] 郭威,张凯,魏新杰,等.高渗透率分布式光伏接入的新型电力系统净功率预测[J].电测与仪表,2022,59(12):48-55.  
GUO Wei,ZHANG Kai,WEI Xinjie,et al.Net power prediction for a novel power system with high permeability distributed photovoltaic access[J].Electrical Measurement & Instrumentation,2022,59(12):48-55.
- [12] 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.
- [13] 姚芳,汤俊豪,陈盛华,等.基于ISSA-CNN-GRU模型的电动汽车充电负荷预测方法[J].电力系统保护与控制,2023,51(16):158-167.  
YAO Fang, TANG Junhao, CHEN Shenghua, et al. Charging load prediction method for electric vehicles based on an ISSA-CNN-GRU model[J]. Power System Protection and Control,2023,51(16):158-167.
- [14] 郭新志,刘英新,李秋燕,等.基于智能负荷控制的分布式能源系统调控策略研究[J].智慧电力,2022,50(3):8-14.  
GUO Xinzhi, LIU Yingxin, LI Qiuyan, et al. Regulation strategy for distributed energy system based on intelligent load control[J]. Smart Power,2022,50(3):8-14.
- [15] 蔡颖凯,张冶,曹世龙,等.面向综合需求响应的综合能源系统优化调度[J].电网与清洁能源,2022,38(9):65-72.  
CAI Yingkai, ZHANG Ye, CAO Shilong, et al. Optimal scheduling of the integrated electricity and natural gas system considering the integrated demand response[J]. Power System and Clean Energy, 2022, 38(9): 65-72.
- [16] 陈泰龙,马玫,陈少磊,等.基于多尺度优化卷积神经网络的配电网电缆局部放电图像识别[J].供用电,2023,40(11):105-111.  
CHEN Tailong, MA Mei, CHEN Shaolei, et al. Cable fault diagnosis of distribution network based on multi-scale optimized convolutional neural network[J]. Distribution & Utilization, 2023, 40(11): 105-111.
- [17] 朱继忠,苗雨旺,董朝阳,等.基于Attention-LSTM与多模型集成的短期负荷预测方法[J].电力工程技术,2023,42(5):138-147.  
ZHU Jizhong, MIAO Yuwang, DONG Zhaoyang, et al. Short-term load forecasting method based on Attention-LSTM and multi-model integration[J]. Electric Power Engineering Technology,2023,42(5):138-147.
- [18] 郭建军,韩铃钰,董佳琦,等.基于SSA-PSO-LSTM模型的羊舍相对湿度预测技术[J].农业机械学报,2022,53(9):365-373.  
CUO Jianjun, HAN Qianyu, DONG Jiaqi, et al. Prediction of sheep house humidity based on SSA PSO LSTM model[J]. Transactions of the Chinese Society for Agricultural Machinery,2022,53(9):365-373.
- [19] 董光德,李道明,陈咏涛,等.基于粒子群优化与卷积神经网络的电能质量扰动分类方法[J].发电技术,2023,44(1):136-142.  
DONG Guangde, LI Daoming, CHEN Yongtao, et al. Power quality disturbance classification method based on particle swarm optimization and convolutional neural network[J]. Power Generation Technology, 2023, 44(1): 136-142.
- [20] 刘文杰,刘禾,王英男,等.基于完整自适应噪声集成经验模态分解的LSTM-Attention网络短期电力负荷预测方法[J].电力建设,2022,43(2):98-108.  
LIU Wenjie, LIU He, WANG Yingnan, et al. Short-term power load forecasting method based on CEEMDAN and LSTM-attention network[J]. Electric Power Construction,2022,43(2):98-108.
- [21] 贾巍,黄裕春.基于小样本数据差分扩容的微电网负荷预测方法[J].中国电力,2023,56(8):151-156+165.  
JIA Wei, HUANG Yuchun. Method of load forecasting in microgrid based on differential expansion of small sample data[J]. Electric Power,2023,56(8):151-156+165.
- [22] 田园园,金国强,彭道刚,等.基于PSO-ABFO的负荷频率控制系统控制器设计与优化[J].电力科学与技术学报,2021,36(6):120-127.  
TIAN Yuanyuan, JIN Guoqiang, PENG Daogang, et al. Design and optimization of load frequency control system controller based on PSO-ABFO[J]. Journal of Electric Power Science and Technology,2021,36(6):120-127.