

引用格式:宋双林,马兆兴,王晶,等.考虑光伏发电功率预测的电动汽车充电优化调控策略[J].电力科学与技术学报,2026,41(1):98-107.

Citation: SONG Shuanglin, MA Zhaoxing, WANG Jing, et al. Charging optimization and regulation strategy for electric vehicles considering photovoltaic power prediction[J]. Journal of Electric Power Science and Technology, 2026, 41(1): 98-107.

考虑光伏发电功率预测的电动汽车 充电优化调控策略

宋双林, 马兆兴, 王晶, 李继, 王瑞华

(青岛理工大学信息与控制工程学院, 山东 青岛 266520)

摘要:规模化电动汽车和分布式电源的普及给电力系统带来了新的挑战,负荷需求和电源供应的波动性与不确定性增加,使得配电网运行面临较大压力。提出了一种考虑光伏功率消纳的电动汽车充电控制策略。首先,采用蒙特卡洛方法对电动汽车用户的用电特征及充电方式进行模拟分析;其次,基于门控循环神经网络理论建立光伏发电预测模型;最后,以光伏消纳最大和用户充电成本最低为充电控制策略目标,采用改进蜣螂优化算法获得了最佳充电策略。仿真结果表明,该充电控制策略在促进光伏功率消纳方面具有有效性和可行性,能够实现电动汽车的有序充电。

关键词:电动汽车;光伏功率预测;有序充电;门控循环单元;新能源

DOI: 10.19781/j.issn.1673-9140.2026.01.010 中图分类号: TM73 文章编号: 1673-9140(2026)01-0098-10

Charging optimization and regulation strategy for electric vehicles considering photovoltaic power prediction

SONG Shuanglin, MA Zhaoxing, WANG Jing, LI Ji, WANG Ruihua

(School of Information and Control Engineering, Qingdao University of Technology, Qingdao 266520, China)

Abstract: The widespread adoption of electric vehicles and distributed power sources poses new challenges to power systems, as increased volatility and uncertainty in both load demand and power supply place greater pressure on distribution network operation. To address these challenges, an electric vehicle charging control strategy considering photovoltaic power accommodation is proposed. First, the Monte Carlo method is employed to simulate and analyze the electricity consumption characteristics and charging behaviors of electric vehicle users. Second, a photovoltaic power generation forecasting model is developed based on gated recurrent unit networks. Finally, an orderly charging control strategy for electric vehicles is proposed, with the objectives of maximum photovoltaic accommodation and minimum charging cost for users, and the improved dung beetle optimization algorithm is used to obtain the optimal charging strategy. The simulation results show that the proposed charging control strategy is effective and feasible in promoting the accommodation of photovoltaic power, and realizes the orderly charging of electric vehicles.

Key words: electric vehicle; photovoltaic power forecasting; orderly charging; gated recurrent unit; new energy

在全球化石能源日渐枯竭和环境污染问题日益严峻的背景下,新能源和电动汽车(electric vehicle, EV)作为绿色能源转型的关键组成部分,正逐渐成为推动能源结构和交通方式变革的重要力

量。然而,随着风电、光伏等新能源发电在发电侧的占比越来越高,其发电的随机性和波动性加剧了传统调频机组的调度压力,导致新能源消纳困难、利用率不高^[1-2]。大规模EV无序并网,相当于在时

收稿日期:2024-11-12;修回日期:2025-04-07

基金项目:国家自然科学基金(62203248);电网运行风险防御技术与装备全国重点实验室资助项目(SG NR0000KJJS2302137)

通信作者:马兆兴(1982—),男,博士,讲师,主要从事电力系统分析、运行以及综合能源系统规划等研究;E-mail:mazhaoxingapple@126.com

间上和空间上的无序电力负荷,会对城市电网造成局部过负荷、线路堵塞等问题,给电网的运行带来巨大冲击^[3-4]。智能控制技术可以优化EV的充电行为,使其与电网运行和新能源发电特性相匹配,提高电力系统运行效率以实现新能源的有效利用,促进新能源消纳。

针对实现EV有序充电的问题,许多学者已经进行了广泛且深入的研究,提出了不同的控制策略。文献[5]通过建立多目标优化模型,以最小化系统负荷总方差和车主充电经济成本为优化目标,实现了EV的优化调度;文献[6]考虑了EV、交通路网及城市电网对EV充电的影响,预测了EV充电负荷,调整了节点电价,从而引导EV有序充电;文献[7]将阶梯碳价与分时电价关联起来,碳交易价改变,电价随之变化,从而通过控制电价平抑负荷波动;文献[8]采用了分区域动态电价机制的充电优化策略,在不同区域建立不同的动态电价,平抑了负荷峰谷差,缓解了电网运行压力;文献[9]提出一种包含电网层和用户层的双层有序充电模型,通过降低负荷峰谷差和减少用户充电费用来控制EV充电。但这些文献的研究范畴仅限于利用电价机制对EV充电进行引导,或者通过控制EV行为平抑电网负荷,未能充分考虑EV负荷在可再生能源消纳方面的作用。

建立EV充电站与可再生能源发电系统的关联,是一种提高可再生能源利用率的有效方式^[10]。文献[11]考虑风电、光伏等可再生能源出力的不确定性,根据充电设备的利用率控制充电站的运行时间,实现EV有序充电;文献[12]根据基础负荷、风电和光伏预测值,制定等效负荷实时电价,引导EV集群充放电;文献[13]针对风机和光伏出力的不确定性对EV充电需求时空分布产生的影响,采用双层规划模型相互约束,共同优化,实现了弃风弃光率最小化;文献[14]针对EV无序充电造成“峰上加峰”的问题,提出分层式有序充电策略,利用概率转移矩阵获得最佳控制策略,降低负荷峰谷差,促进新能源消纳。上述文献未考虑不同类型EV的出行特性对充电负荷的影响,且主要对私家车进行分析,对光伏发电功率的建模过于简单,未考虑温度、太阳辐照度等因素的变化对光伏发电功率的影响。

基于上述研究,本文针对可再生能源发电量大,但并网消纳难的问题,将EV充电站与光伏发电系统关联起来,提出考虑光伏功率消纳的EV充电控制策略。首先,通过考虑不同类型EV的出行特征,采用蒙特卡洛模拟方法生成EV充电负荷曲线;其次,采用变分模态分解(variational mode decomposition, VMD)对原始光伏功率数据进行分解,采用改进蜣螂优化(dung beetle optimizer, DBO)算法优化的门控循环单元(gated recurrent unit, GRU)预测模型对各个分量分别进行预测,并将各分量的预测结果汇总,得出最终的预测输出;再次,为实现光伏功率的最大化消纳和用户充电成本最低,构建以实际充电功率与光伏发电功率的偏差和EV用户充电费用的多目标优化函数,最小化该目标函数,实现EV有序充电的科学调度;最后,采用改进DBO算法对系统优化目标进行寻优求解,降低用户充电成本和实现光伏功率利用最大化。

1 EV充电负荷模型

本文将EV划分为4个不同的类别:私家车、公交车、出租车和商用车,具体分析各类型车辆的充电模式、充电次数、充电开始时间分布和起始充电容量分布,研究各类型车辆的充电负荷需求。

不同类型的EV充电负荷在时间和空间上都具有随机性^[15],EV的起始充电时间遵循正态分布的概率密度函数,本文近似地认为4类用户群体的充电初始时刻和充电起始荷电状态(state of charge, SOC)概率分布均满足正态分布:

$$f(t) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(t-\mu)^2}{2\sigma^2}\right) \quad (1)$$

式中, $f(t)$ 为概率密度函数; μ 、 σ 分别为正态分布的均值和方差; t 为EV的出行时刻。

4种EV的充电负荷如下。

1) 私家车负荷。私家车在工作日的出行特征和模型参数与节假日的有所不同。本文设定私家车以每日一次的频率进行充电,在白天和夜间灵活选择快充和慢充模式,但大多数用户在白天选择快充模式,在傍晚或夜间选择慢充模式。

2) 公交车负荷。公交车运营时间大致为06:00—22:00,以一天两充的频率进行充电,通常在中午时段选择快充,夜间选择慢充。

3) 出租车负荷。出租车运营时间为全天,以一天两充的频率进行充电,充电时段选择在客流量较少的时段,分别为中午和午夜,通常选择快充模式。

4) 商用车负荷^[16]。商用车往往在白天用于出行,以一天一充的频率在夜晚选择慢充模式进行充电。表1列出了各类型EV的充电参数。

表1 EV的充电参数

Table 1 Charging parameters of electric vehicles

| 车辆类型 | 充电次数/次 | 充电概率 | 充电模式 | 充电时段 | 充电开始时间的概率分布 | 充电起始SOC的概率分布 |
|--------------|--------|------|------|---------------|--------------------|-----------------|
| 私家车 (工作日) | 1 | 0.2 | 快充 | 07:00—18:00 | $N(9, 3^2)$ | $N(0.3, 0.1^2)$ |
| | | 0.8 | 慢充 | 18:00—次日07:00 | $N(20, 1.6^2)$ | $N(0.3, 0.1^2)$ |
| 私家车 (节假日) | 1 | 0.2 | 快充 | 07:00—18:00 | $N(12, 3^2)$ | $N(0.3, 0.1^2)$ |
| | | 0.8 | 慢充 | 18:00—次日07:00 | $N(20, 2.5^2)$ | $N(0.3, 0.1^2)$ |
| 公交车 | 2 | 1.0 | 快充 | 12:00—16:00 | $N(14, 1^2)$ | $N(0.5, 0.1^2)$ |
| | | 1.0 | 慢充 | 18:00—次日2:00 | $N(22, 2^2)$ | $N(0.5, 0.1^2)$ |
| 出租车 | 2 | 1.0 | 快充 | 01:00—05:00 | $N(3, 1.6^2)$ | $N(0.2, 0.1^2)$ |
| | | 1.0 | 快充 | 10:00—14:00 | $N(12, 1.6^2)$ | $N(0.5, 0.1^2)$ |
| 商用车 | 1 | 0.5 | 慢充 | 16:00—20:00 | $N(17.68, 0.76^2)$ | $N(0.3, 0.1^2)$ |

为了简化模型计算,本研究假设EV的充电过程以恒定功率进行,因此单辆EV所需的充电时间可以表示为

$$t_c = \frac{(1 - S_{\text{soc}})C}{P_c} \quad (2)$$

式中, t_c 为充电时长; S_{soc} 为充电时EV的荷电状态; C 为EV容量; P_c 为EV充电功率。

通过累加得到区域内EV集群的充电负荷如下:

$$P_{\text{ev},t} = \sum_i^N P_{\text{ev},i,t} \quad (3)$$

式中, $P_{\text{ev},t}$ 为EV在 t 时段内总的充电负荷; N 为EV的总数; $P_{\text{ev},i,t}$ 为第 i 个EV在 t 时段内的充电功率。

2 光伏预测模型相关原理

2.1 VMD

光伏发电功率受温度、气压、辐射等多种因素的影响,一般为非平稳序列。为了提高预测精度,减少光伏发电功率时间序列非平稳性的影响,本文采用VMD将光伏发电功率序列分解为若干个子时间序列,并分别对这些子时间序列进行预测。

VMD是一种由文献[17]在2014年提出的先进信号处理技术,该方法能够将原始信号分解为一系列具有不同中心频率和带宽的本征模态分量^[18],能够自适应地为每种模态匹配最佳的中心频率和带宽,有效分离固有模态函数(intrinsic

mode function, IMF)分量,并克服端点效应和模态混叠问题。其约束变分模型为

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t. } \sum_{k=1}^K u(t) = f_s(t), k = 1, 2, \dots, K \end{cases} \quad (4)$$

式中, $\{u_k\} = \{u_1, u_2, \dots, u_k\}$ 表示分解得到的 k 个固有模态分量; $\{\omega_k\} = \{\omega_1, \omega_2, \dots, \omega_k\}$ 表示 k 个IMF分量对应的中心频率; K 为分解得到的模态总数; $\delta(t)$ 为狄拉克分布; $u_k(t)$ 为 t 时刻第 k 个IMF分量; t 为时间; $f_s(t)$ 为 t 时刻的原始光伏功率信号。

通过引入惩罚因子 α 和拉格朗日算子 λ 将带有约束的变分优化模型转换成增广拉格朗日形式,从而将约束优化问题转化为非约束优化问题:

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \left(\lambda(t), f_s(t) - \sum_{k=1}^K u_k(t) \right) + \left\| f_s(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \\ & \alpha \sum_{k=1}^K \left\| \partial_t \left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) e^{-j\omega_k t} \right\|_2^2 \end{aligned} \quad (5)$$

式中, $\lambda(t)$ 为随时间 t 变化的拉格朗日算子。

利用交替方向乘子算法不断地更新各模态分量和中心频率,如下:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{x}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}^n(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^n)^2} \quad (6)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^n(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^n(\omega)|^2 d\omega} \quad (7)$$

式中, $\hat{u}_k^{n+1}(\omega)$ 、 $\hat{x}(\omega)$ 、 $\hat{u}_i(\omega)$ 、 $\hat{\lambda}^n(\omega)$ 分别为 $u_k^{n+1}(t)$ 、 $x(t)$ 、 $u_i(t)$ 、 $\lambda^n(t)$ 的傅里叶变换; ω 为频率; n 为迭代次数。

2.2 GRU 神经网络模型

GRU 中包含更新门 (update gate) 和重置门 (reset gate) 两个门控结构。这两个门控结构可以帮助 GRU 在处理长序列时有效地解决梯度消失问题, 从而有效地捕获长期依赖关系^[19], 同时简化了长短期记忆网络 (long short term memory, LSTM) 的结构。GRU 能够建立当前输入与输出变量之间的关系, 而且能够捕捉相邻时间步输出之间的时序关联, 具有强大的时间序列学习能力^[20-22]。GRU 中各单元计算如下:

$$\begin{cases} z_t = \sigma(W^{(z)}x_t + U^{(z)}h_{t-1}) \\ r_t = \sigma(W^{(r)}x_t + U^{(r)}h_{t-1}) \\ \tilde{h}_t = \tanh(r_t \odot Uh_{t-1} + Wx_t) \\ h_t = (1 - z_t) \odot \tilde{h}_t + z_t \odot \tilde{h}_{t-1} \end{cases} \quad (8)$$

式中, z_t 为更新门的输出; σ 为激活函数; x_t 为当前时刻的输入; h_{t-1} 为前一时刻的隐藏状态; $W^{(z)}$ 、 $U^{(z)}$ 为更新门中的权重矩阵; r_t 为重置门输出; h_t 为当前的隐藏状态; \tilde{h}_t 为当前候选隐藏状态; U 、 W 为计算 h_t 的权重矩阵; \odot 表示逐元素乘法。

3 VMD-IDBO-GRU 光伏预测模型

3.1 DBO 算法的改进

DBO 算法是一种新型无梯度的群智能优化算法, 其灵感来源于蜣螂的行为特征, 通过模拟蜣螂的滚球、跳舞、觅食、繁殖和盗窃行为来更新候选解^[23], 具有寻优能力强、收敛速度快和抗噪声能力强等优点, 适合解决复杂的优化问题。具体原理参考文献^[24], 改进的蜣螂优化 (improved dung beetle optimizer, IDBO) 算法的主要步骤如下。

1) 受鲸鱼优化算法^[25]的启发, 在蜣螂繁殖和蜣螂觅食位置更新阶段引入可变螺旋搜索策略, 使得蜣螂位置更新更加灵活, 增加蜣螂个体的多样性, 避免陷入局部最优, 提高算法的收敛速度和全局搜索能力。可变螺旋搜索策略如下:

$$\begin{cases} X_{i,j}^{t+1} = \\ e^{z^l} \cos(2\pi l) Q e^{\frac{X_{i,j}^t - X_{i,j}^{\text{worst}}}{2}}, & i > \frac{n}{2} \\ X_P^{t+1} + |X_{i,j}^t - X_P^{t+1}| A^+ L e^{z^l} \cos(2\pi l), & \text{其他} \end{cases} \quad (9)$$

式中, l 为 $[-1, 1]$ 中均匀变化的随机数; z 为螺旋搜索形状的参数, $z = e^{k \cdot \cos(\frac{\pi t}{\max t})}$; k 为变化系数, $k = 5$; $X_{i,j}^{t+1}$ 为第 $t+1$ 次迭代中第 i 个卵球在第 j 维的位置; Q 为 $[0, 1]$ 中均匀变化的随机数; $X_{i,j}^{\text{worst}}$ 为当前群体中适应度最差的卵球位置; n 为种群中个体总数量; X_P^{t+1} 为第 $t+1$ 次迭代随机选择的个体位置; A^+ 为控制系数; L 为控制参数, 用于控制策略的步长, $L = 2r - 1$; r 为 $[0, 1]$ 中的随机数。

此时, 繁殖蜣螂的位置更新公式为

$$\begin{aligned} B_i(t+1) = \\ X^* + e^{z^l} \cos(2\pi l) b_1 (B_i(t) - b_L^*) + \\ e^{z^l} \cos(2\pi l) b_2 (B_i(t) - b_U^*) \end{aligned} \quad (10)$$

式中, X^* 为当前局部最优解; $B_i(t)$ 为第 t 次迭代时第 i 个卵球的位置; b_1 、 b_2 分别为两个独立大小为 $1 \times d$ 的随机向量; b_U^* 、 b_L^* 分别为产卵区域的上界和下界。

此时, 觅食蜣螂的位置更新公式为

$$\begin{aligned} x_i(t+1) = \\ e^{z^l} \cos(2\pi l) x_i(t) + c_1 (x_i(t) - b_L) + \\ c_2 (x_i(t) - b_U) \end{aligned} \quad (11)$$

式中, $x_i(t)$ 为觅食蜣螂 i 在第 t 次迭代的位置; c_1 为服从正态分布的随机数; $c_2 \in [0, 1]$ 为随机数; b_U 和 b_L 分别为最佳觅食区域的上界和下界。

2) 为提高算法寻优能力, 跳出局部最优, 在后期引入高斯变异算子, 标准高斯分布的概率密度函数如下:

$$\text{Gauss}(0, 1) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}, x \in (0, 1) \quad (12)$$

融入高斯变异算子后, 算法收敛性能得到改善, 增加了种群多样性, 有利于提高跳出局部最优值的能力。

融入高斯变异算子后, 位置更新公式变为

$$\begin{aligned} x_{i,\text{best}}(t+1) = \\ x_i(t+1) + x_i(t+1) \times \text{Gauss}(0, 1) \end{aligned} \quad (13)$$

式中, $x_{i,\text{best}}(t)$ 为觅食蜣螂 i 在第 t 次迭代的最佳位置。

3.2 VMD-IDBO-GRU 预测模型流程

单一的模型方法均存在一定的局限性, 本文通过 VMD, 结合改进 DBO 算法对 GRU 进行优化, 采用学习速度快和稳定性较好的 GRU 神经网络进行

相关预测,以此挖掘出光伏发电功率关于时间序列的变化规律。具体步骤如下。

1) 原始光伏数据经过 VMD 算法后得到不同特征和中心频率的模态分量,各模态分量采用滑动窗口进行处理,得到时间步长为 T 的序列样本集,将前 T 个时刻的数据作为特征向量用于预测第 $T+1$ 时刻的输出数据。

2) 初始化 GRU 神经网络的参数,采用改进的 DBO 算法对模型的隐藏单元层数、训练次数和初始学习率等超参数进行寻优处理,从而确定最佳超参数。将步骤 1) 分解得到的各模态分量作为 GRU 的输入向量进行训练,最终获得每个模态分量对应的预测输出值。

3) 对不同的模态分量的预测值进行融合叠加,汇集出最终的光伏功率预测结果,进一步对预测结果进行验证和误差分析。

VMD-IDBO-GRU 预测模型流程如图 1 所示。

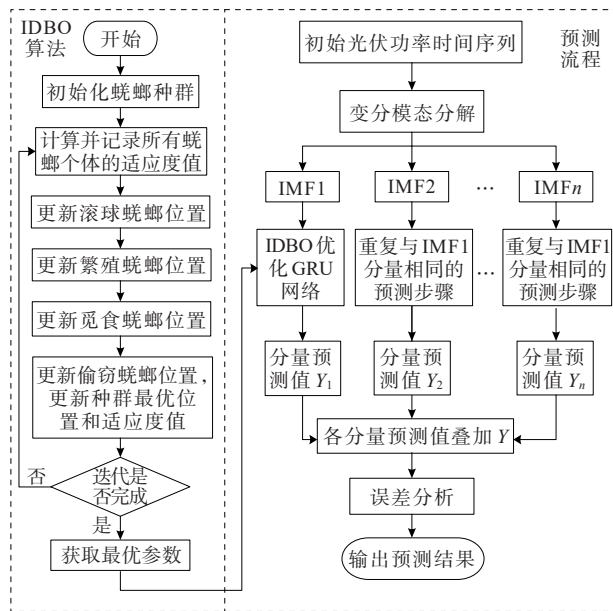


图 1 VMD-IDBO-GRU 模型预测流程

Figure 1 Prediction procedure of VMD-IDBO-GRU model

3.3 模型评价指标

利用构建的 LSTM、VMD-LSTM、GRU、VMD-GRU、VMD-DBO-GRU、VMD-IDBO-GRU 这 6 种模型对光伏发电功率数据进行预测,采用平均绝对误差(mean absolute error, MAE) E_{MAE} 、均方根误差(root-mean-square error, RMSE) E_{RMSE} 和平均绝对百分比误差(mean absolute percentage error, MAPE) E_{MAPE} 对模型的精确性进行相关评估^[26]:

$$E_{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (14)$$

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

$$E_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (16)$$

式中, y_i 为光伏发电功率的真实数据值; \hat{y}_i 为预测值; n 为总数据量。

4 考虑新能源消纳的 EV 充电控制策略

本文研究的电网系统结构如图 2 所示,光伏发电系统经过变压器并入大电网,各类型 EV 通过充电站与电网连接,实现电能的双向流动。控制中心接收光伏发电站上传的 EV 充电负荷和光伏发电功率预测数据,在保证控制前后 EV 充电总负荷不变的前提下,以 EV 集群实际充电功率与光伏功率偏差最小和充电费用最低为目标,对 EV 进行充电功率分配,实现 EV 的有序充电。

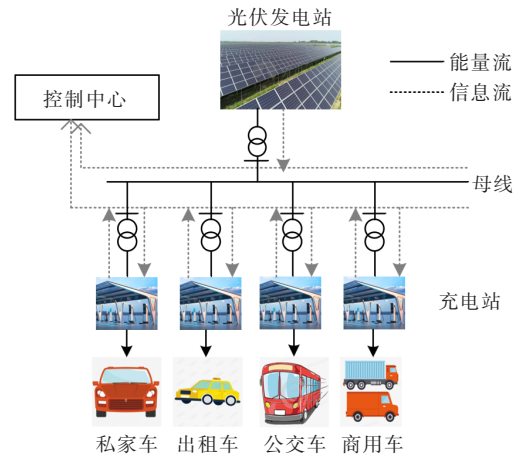


图 2 电网系统结构

Figure 2 Structure of power grid system

4.1 目标函数及约束条件

1) 目标函数。

考虑光伏功率消纳最大和用户充电成本最低,本文以实现 EV 集群实际充电功率与光伏发电功率的偏差最小和用户充电费用最低为目标,相关目标函数表达式如下:

$$F_1 = \sum_{t=1}^T (P_{ev,t}^* - P_{pv,t})^2 \quad (17)$$

$$F_2 = \sum_{t=1}^T (P_{ev,t}^* C_t) \quad (18)$$

式中, F_1 、 F_2 分别为 EV 实际充电功率与光伏功率的

偏差、用户实际充电费用; $P_{ev,t}^*$ 为 EV 集群在 t 时刻的实际充电功率; $P_{pv,t}$ 为 t 时刻的光伏发电输出功率; c_t 为 t 时刻的 EV 充电电价。

2) 约束条件。

电网最大功率限制如下:

$$P_{load,t} + P_{ev,t}^* - P_{pv,t} \leq P_{max,t} \quad (19)$$

式中, $P_{load,t}$ 为 t 时刻系统基础负荷; $P_{max,t}$ 为 t 时刻电网运行的最大功率。

EV 荷电状态限制如下:

$$S_{SOC,min} \leq S_{SOC,t} \leq S_{SOC,max} \quad (20)$$

式中, $S_{SOC,t}$ 为 t 时段的荷电状态; $S_{SOC,min}$ 、 $S_{SOC,max}$ 分别为 EV 的 SOC 的下限和上限。

EV 集群的充电功率限制如下:

$$0 \leq P_{ev,t}^* \leq NP_{ev,max} \quad (21)$$

式中, N 为 EV 的数量; $P_{ev,max}$ 为 EV 的最大充电功率。

光伏出力约束如下:

$$0 \leq P_{pv,t} \leq P_{pv,max} \quad (22)$$

式中, $P_{pv,max}$ 为光伏发电的最大发电功率。

充电电量约束如下:

$$\sum_t P_{ev,t}^* = \sum_t P_{ev,t} \quad (23)$$

式中, T 为总充电时长。为满足用户出行需求, EV 无序充电和有序充电总负荷保持不变。

4.2 模型求解

本文在 MATLAB 平台采用蒙特卡洛模拟方法和 IDBO 算法对模型进行求解, 模型求解流程如图 3 所示, 算法采用加权和法将多目标函数归一化成单目标, 如下:

$$F = \omega_1 \left(\frac{F_1}{F_{1max}} \right) + \omega_2 \left(\frac{F_2}{F_{2max}} \right) \quad (24)$$

式中, F_{1max} 、 F_{2max} 分别为偏差最大值和充电费用最大值; ω_1 、 ω_2 为权重系数, $\omega_1 + \omega_2 = 1$ 。

具体求解步骤如下。

1) 输入各类 EV 充电负荷参数, 采用蒙特卡洛方法生成 EV 充电负荷曲线。

2) 将 EV 负荷曲线和光伏出力功率数据传输到控制中心。

3) 控制中心首先将数据初始化, 随后判断此时是否需要 EV 进行调度。不需要调度时, EV 维持原充电状态; 需要调度时, 采用 IDBO 算法对目标函数进行优化, 得到此时 EV 的充电功率。

4) 判断时间数值是否达到 24, 若达到则输出最优解, 否则执行步骤 3) 直至调度完毕, 结束该天调度。

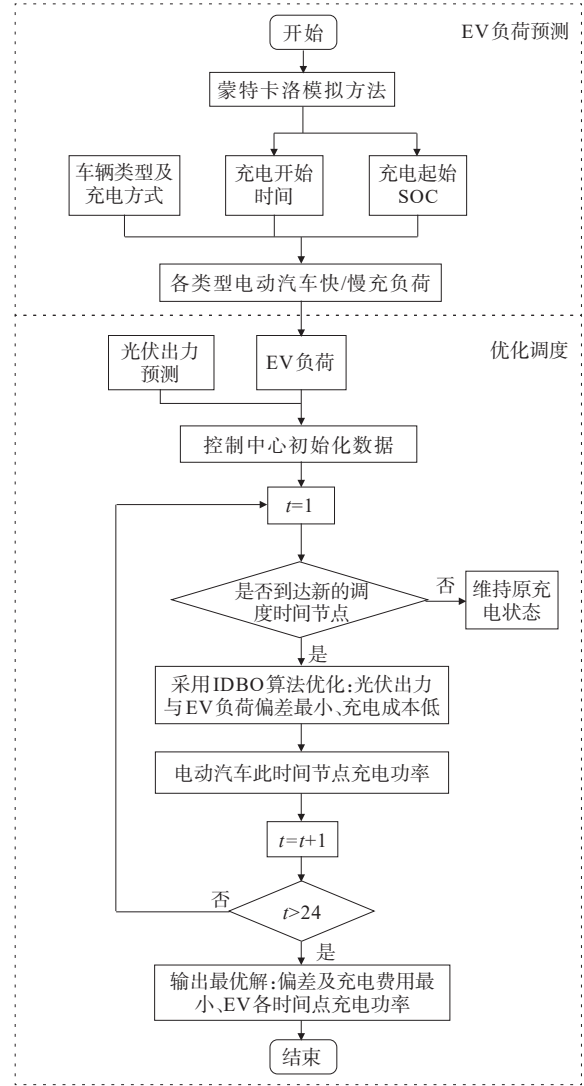


图 3 模型求解流程

Figure 3 Model solution process

5 仿真与分析

5.1 光伏发电系统功率预测仿真分析

为验证模型的有效性和可行性, 本文选取区域内光伏发电场 60 d 的实测数据, 光伏数据采集频率均为 15 min/次, 对未来 1 d 内 96 个采样点数据进行预测, 对统计好的历史数据进行 VMD, 设置模态分解个数为 $K=7$, 惩罚参数设置为 $\alpha=2000$, 收敛判据 $\tau=10^{-7}$ 。VMD 分解结果如图 4 所示。

由图 4 可以看出, 原始光伏功率信号被分解为低频高振分量 IMF1~IMF3 以及高频低振分量 IMF4~IMF7, 它们能够捕捉并表征原始数据中影响光伏功率变化的关键因素。其中, IMF1 为主导分量, 准确地捕捉了光伏输出功率的变化趋势。

将分解后的模态数据代入 GRU, 基于历史数据

特征进行预测,采用IDBO算法确定GRU模型参数;将得到的各个模态预测结果进行累加,得到总的功率预测结果。为验证所提模型的预测效果,本文采用LSTM、VMD-LSTM、GRU、VMD-GRU、VMD-DBO-GRU和VMD-IDBO-GRU这6种预测模型进行对比分析,预测结果如图5所示。从图5可以看出,各模型的预测结果均接近真实值,均可以较好地拟合真实值的变化趋势,表明深度学习在光伏功率预测方面具有良好的性能。其中VMD-IDBO-GRU模型的预测值曲线更接近真实值,能够较好地跟踪真实值曲线。




图4 VMD分解结果

Figure 4 Results of VMD decomposition

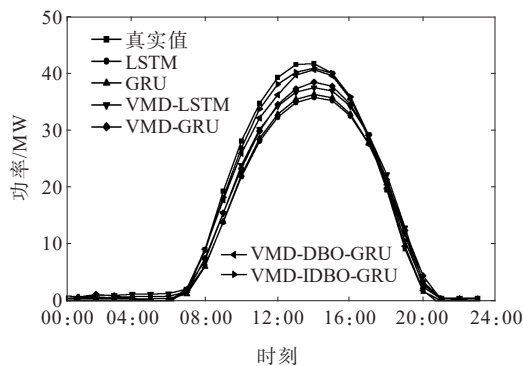


图5 不同模型预测结果

Figure 5 Prediction results of different models

各模型评价指标如表2所示。由表2可知,GRU与LSTM相比,其RMSE、MAE、MAPE分别降低了6.6%、9.4%和1.30个百分点,表明GRU模型的预测能力较强。VMD-GRU对初始数据进行分解后,其RMSE、MAE、MAPE比GRU模型分别降低了24.32%、18.36%和3.99个百分点,验证了VMD算法的降噪优化有助于提高预测精度。

VMD-IDBO-GRU预测模型相较于VMD-DBO-GRU,其RMSE、MAE、MAPE分别降低了34.89%、19.57%和2.13个百分点,表明本文所提预测模型能够对光伏功率进行精确预测。

表2 各模型评价指标

Table 2 Evaluation indicators of different prediction models

| 模型 | RMSE | MAE | MAPE/% |
|--------------|---------|---------|--------|
| LSTM | 3.543 2 | 2.550 5 | 14.99 |
| GRU | 3.311 0 | 2.310 4 | 13.69 |
| VMD-LSTM | 2.694 2 | 2.126 3 | 10.60 |
| VMD-GRU | 2.505 6 | 1.886 3 | 9.70 |
| VMD-DBO-GRU | 1.308 3 | 0.907 1 | 5.16 |
| VMD-IDBO-GRU | 0.851 9 | 0.729 7 | 3.03 |

为了考察VMD-IDBO-GRU模型的预测准确性,本文提出的原假设为模型预测结果与真实值无差异,将真实值与模型预测值进行显著性检验,验证试验的 p 值为0.697,远大于0.05,不能拒绝原假设,表明VMD-IDBO-GRU模型预测值与真实值之间不存在显著性差异,该模型具有较好的预测准确性;为了进一步验证模型性能提升的显著性,将VMD-IDBO-GRU预测模型分别与其余5种预测模型进行配对 t 检验,结果如表3所示。假设检验结果均小于置信水平为95%下的显著性水平0.05,结果表明,显著性水平为0.05时,模型预测结果无差异的原假设不成立,VMD-IDBO-GRU预测模型具有更加显著的优势。

表3 配对 t 检验结果

Table 3 Results of paired t -test

| 配对情况 | t | p |
|-----------------------------|-------|-------|
| VMD-IDBO-GRU 配对 LSTM | 3.336 | 0.003 |
| VMD-IDBO-GRU 配对 GRU | 2.866 | 0.009 |
| VMD-IDBO-GRU 配对 VMD-LSTM | 2.080 | 0.010 |
| VMD-IDBO-GRU 配对 VMD-GRU | 2.040 | 0.036 |
| VMD-IDBO-GRU 配对 VMD-DBO-GRU | 1.530 | 0.040 |
| 真实值 配对 VMD-IDBO-GRU | 0.395 | 0.697 |

5.2 仿真分析

本文基于文1和VMD-IDBO-GRU方法分别搭建EV负荷模型和光伏发电功率预测模型,实现了对EV负荷的模拟分析,并能够精确预测区域内的光伏发电功率,最终得到如图6所示的含EV无序充电的总负荷功率曲线。EV充电电价如表4所示。由图6可知,光伏输出功率从08:00开始不断上升,再从14:00开始不断递减直到20:00。在EV未接

入电网的情况下,电网基础负荷的用电高峰处于 18:00—22:00 时段,此时电网峰值负荷和谷值负荷的差值为 57 MW。当大规模 EV 以无序充电方式接入电网后,EV 充电负荷的高峰期与基础负荷用电高峰期相重合,两者叠加后导致综合负荷峰谷差扩大到 89 MW,加剧了电网“峰上加峰”的问题,对系统正常运行带来了重大挑战。




图 6 含 EV 无序充电的总负荷

Figure 6 Total load including disorderly charging of electric vehicles

表 4 EV 充电电价

Table 4 Electricity prices for EV charging

| 时段 | 电价/元 |
|-------------|-------|
| 00:00—08:00 | 0.230 |
| 08:00—16:00 | 0.585 |
| 16:00—24:00 | 0.890 |

为了验证所提控制策略对光伏的消纳能力,本文设置了以下 3 种情形进行对比分析。

1) 情形 1:根据文 1 的 EV 参数生成 EV 无序充电曲线。

2) 情形 2:以平抑电网负荷波动为目标生成 EV 充电曲线。

3) 情形 3:采用本文所提的控制策略,通过充电费用和光伏功率消纳来控制 EV 用户充电行为。

不同情形下 EV 无序和有序充电的充电负荷曲线如图 7 所示。在无序充电情况下,EV 主要受用户的行为习惯影响而随机充电,不会对电价和光伏功率的变化做出响应。因此,充电高峰期集中在傍晚,造成线路过载,较多的光伏功率未被利用。情形 2 以平抑电网负荷波动为目标,优化后的 EV 充电时间集中在夜间,充电负荷在夜间达到尖峰,而光伏出力在中午出力最大,对光伏功率消纳的能力有限,造成了巨大的电能浪费。

考虑光伏消纳后,控制中心根据光伏功率的变化合理安排 EV 有序充电。从图 7 可以看出,EV 充

电负荷曲线与光伏总功率曲线趋势一致,EV 随着光伏功率的变化能够更好地吸收电能,充电负荷从电网负荷高峰期向光伏出力充足的时段转移,减少向电网购电的成本,多余的光伏功率可供基础负荷消耗,减少系统对电网的依赖。




图 7 不同情形下 EV 无序和有序充电的充电负荷曲线

Figure 7 Charging load curves of electric vehicles under different disorderly and orderly charging scenarios

优化前、后 EV 仿真结果对比如表 5 所示。从表 5 可知,与情形 1 相比,虽然情形 2 中 EV 与光伏功率的偏差和用户充电费用均减少,但其对光伏功率的总体利用量远低于情形 1,加剧了光伏功率的浪费。在本文所提的控制策略下,EV 与光伏功率的偏差减少了 346.97 MW, EV 充电费用减少了 4.26 万元,光伏功率利用量增加了 121.11 MW。因此,本文所提的控制策略不仅降低了系统净负荷波动,促进了光伏功率消纳,降低了 EV 用户的充电费用,而且增加了光伏功率的利用量。

表 5 优化前、后 EV 仿真结果对比

Table 5 Comparison of EV simulation results before and after optimization

| 情形 | EV 与光伏功率的偏差/MW | EV 充电费用/万元 | 光伏功率利用量/MW |
|----|----------------|------------|------------|
| 1 | 436.17 | 22.19 | 118.21 |
| 2 | 300.51 | 20.64 | 88.28 |
| 3 | 89.20 | 17.93 | 239.32 |

6 结语

本文基于 GRU 神经网络理论建立了光伏预测模型,使用 IDBO 算法提高了模型的预测精度,可对未来光伏发电进行精确预测。针对大量可再生能源并网后导致的消纳问题,本文提出了基于光伏发电功率预测的 EV 充电优化控制策略,该策略根据光伏功率的预测结果确定 EV 集群的最优充电时间,并采用 IDBO 算法进行迭代求解,通过分析研究

可得到以下结论。

1) 采用 VMD 提高了光伏输出功率的预测精度,本文所提 IDBO 算法提升了 GRU 神经网络参数的寻优能力,明显减小了预测误差,评价指标 MAE、RMSE、MAPE 取得了最小值,显现出良的好精度。

2) 本文提出的有序充电控制策略能够基于光伏发电功率的出力情况,实现对 EV 集群充电时间的合理调控,大幅降低了光伏功率与 EV 集群负荷之间的偏差,提高了光伏功率的利用率,降低了向电网购电的成本,使 EV 能够优先消纳光伏功率,实现了低碳环保。

3) 通过实验仿真证明,本文所提控制策略能够有效实现电网负荷的削峰填谷,大幅降低电网负荷峰谷差,并保障 EV 用户的充电权益,更好地引导 EV 用户的充电行为。

本文所提出的考虑光伏发电功率预测的 EV 有序充电策略有效地提升了光伏的用能效率,但对 EV 的建模只考虑了时间层面,未考虑空间转移对 EV 充电负荷的影响,在后续研究中可做进一步探讨。

参考文献:

- [1] JIN B H. Impact of renewable energy penetration in power systems on the optimization and operation of regional distributed energy systems[J]. *Energy*, 2023, 273: 127201.
- [2] 陈先龙,王秀丽,陈洁,等.考虑分布式可再生能源交易的风电商与电动汽车充电站协同优化调度[J]. *电网技术*, 2023, 47(11): 4598-4610.
CHEN Xianlong, WANG Xiuli, CHEN Jie, et al. Optimal collaborative scheduling of wind power operators and electric vehicle charging stations considering distributed renewable energy trading[J]. *Power System Technology*, 2023, 47(11): 4598-4610.
- [3] 胡泽春,宋永华,徐智威,等.电动汽车接入电网的影响与利用[J]. *中国电机工程学报*, 2012, 32(4):1-10+25.
HU Zechun, SONG Yonghua, XU Zhiwei, et al. Impacts and utilization of electric vehicles integration into power systems[J]. *Proceedings of the CSEE*, 2012, 32(4): 1-10+25.
- [4] 王锡凡,邵成成,王秀丽,等.电动汽车充电负荷与调度控制策略综述[J]. *中国电机工程学报*, 2013, 33(1):1-10.
WANG Xifan, SHAO Chengcheng, WANG Xiuli, et al. Survey of electric vehicle charging load and dispatch control strategies[J]. *Proceedings of the CSEE*, 2013, 33(1):1-10.
- [5] 潘华,肖雨涵,梁作放,等.基于改进隶属度函数的电动汽车充放电多目标优化调度模型[J]. *电力科学与技术学报*, 2021, 36(6): 85-93.
PAN Hua, XIAO Yuhuan, LIANG Zuofang, et al. Multi-objective optimal scheduling of electric vehicle charging and discharging based on improved membership functions[J]. *Journal of Electric Power Science and Technology*, 2021, 36(6): 85-93.
- [6] 姜晓锋,魏巍,王永灿,等.“车-路-网”协同优化下的电动汽车有序充电引导策略[J]. *电力科学与技术学报*, 2023, 38(5): 44-56.
JIANG Xiaofeng, WEI Wei, WANG Yongcan, et al. Orderly charging guidance strategies for electric vehicles under EVs-traffic-distribution collaborative optimization [J]. *Journal of Electric Power Science and Technology*, 2023, 38(5): 44-56.
- [7] 王均,黄柯然,许潇,等.基于阶梯碳价和自适应分时电价的电动汽车有序充电[J]. *电力自动化设备*, 2024, 44(2): 64-71.
WANG Jun, HUANG Keran, XU Xiao, et al. Ordered charging of electric vehicles based on ladder-type carbon price and adaptive time-of-use electricity price[J]. *Electric Power Automation Equipment*, 2024, 44(2): 64-71.
- [8] 邓衍辉,李剑,卢国强,等.考虑分区域动态电价机制引导的电动汽车充电优化策略[J]. *电力系统保护与控制*, 2024, 52(7): 33-44.
DENG Yanhui, LI Jian, LU Guoqiang, et al. Charging optimization strategy of electric vehicles guided by the dynamic tariff mechanism of a subregion[J]. *Power System Protection and Control*, 2024, 52(7): 33-44.
- [9] 康童,朱吉然,冯楚瑞,等.面向光储充一体化社区的有序充电策略研究[J]. *电力系统保护与控制*, 2024, 52(9): 132-142.
KANG Tong, ZHU Jiran, FENG Churui, et al. An orderly charging strategy for a photovoltaic-storage-charging integrated community[J]. *Power System Protection and Control*, 2024, 52(9): 132-142.
- [10] 段俊东,李高尚,李一石,等.考虑风电消纳的电动汽车充电站有序充电控制[J]. *储能科学与技术*, 2021, 10(2): 630-637.
DUAN Jundong, LI Gaoshang, LI Yishi, et al. Coordinated charging control for EV charging stations considering wind power accommodation[J]. *Energy Storage Science and Technology*, 2021, 10(2): 630-637.
- [11] LI C Z, ZHANG L B, OU Z H, et al. Robust model of electric vehicle charging station location considering renewable energy and storage equipment[J]. *Energy*, 2022, 238: 121713.
- [12] 骆徐,程静,王李鑫,等.基于等效负荷实时电价和节点实时电价引导的电动汽车时空优化调度[J]. *电网技术*,

- 2025,49(11):4670-4679.
- LUO Xu, CHENG Jing, WANG Lixin, et al. Spatio-temporal optimal scheduling of electric vehicles based on equivalent load real-time tariff and node real-time tariff guidance[J]. *Power System Technology*, 2025, 49(11):4670-4679.
- [13] 丁屹峰,曾爽,张宝群,等. 光伏-直流智能充电桩有序充电策略与应用效果[J]. *中国电力*, 2024, 57(5): 70-77. DING Yifeng, ZENG Shuang, ZHANG Baoqun, et al. Orderly charging strategy and application effect of PV-DC intelligent EV chargers[J]. *Electric Power*, 2024, 57(5): 70-77.
- [14] 马苗苗,任智伟,刘立成,等. 考虑新能源消纳的电动汽车有序充电控制策略[J]. *太阳能学报*, 2024, 45(8): 94-103. MA Miaomiao, REN Zhiwei, LIU Licheng, et al. Orderly charging control strategy for electric vehicles considering new energy accommodation[J]. *Acta Energetica Solaris Sinica*, 2024, 45(8): 94-103.
- [15] 夏鑫,钟浩,张磊,等. 计及动态电价的电动汽车参与微电网调度双层优化策略[J]. *电力工程技术*, 2024, 43(3): 140-150. XIA Xin, ZHONG Hao, ZHANG Lei, et al. A two-layer optimization strategy for electric vehicles participating in microgrid scheduling considering dynamic electricity prices[J]. *Electric Power Engineering Technology*, 2024, 43(3): 140-150.
- [16] 游磊,金小明,刘云. 电动汽车集群充电负荷计算方法研究[J]. *南方能源建设*, 2024, 11(5): 159-167. YOU Lei, JIN Xiaoming, LIU Yun. Research on the charging load calculation method for electric vehicle cluster [J]. *Southern Energy Construction*, 2024, 11(5): 159-167.
- [17] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. *IEEE Transactions on Signal Processing*, 2014, 62(3): 531-544.
- [18] 邹港,赵斌,罗强,等. 基于 PCA-VMD-MVO-SVM 的短期光伏输出功率预测方法[J]. *电力科学与技术学报*, 2024,39(5):163-171. ZOU Gang, ZHAO Bin, LUO Qiang, et al. Prediction method of short-term PV output power based on PCA-VMD-MVO-SVM[J]. *Journal of Electric Power Science and Technology*,2024,39(5):163-171.
- [19] 高晨元,田建艳,姬政雄,等. 基于门控循环单元残差连接网络与多任务学习的园区综合能源系统多元负荷预测[J]. *电网技术*,2025,49(5):1771-1780. GAO Chenyuan, TIAN Jianyan, JI Zhengxiong, et al. Multivariate load forecasting for park-level integrated energy system based on gated recurrent unit residual connection network and multi-task learning[J]. *Power System Technology*,2025,49(05):1771-1780.
- [20] CHO K, VAN MERRIENBOER B, BAHDANAU D, et al. On the properties of neural machine translation: encoder-decoder approaches[C]//*Proceedings of SSST-8, Eighth Workshop on Syntax, Semantics and Structure in Statistical Translation*. Doha, Qatar. Stroudsburg, PA, USAACL, 2014: 103-111.
- [21] 赵兵,王增平,纪维佳,等. 基于注意力机制的 CNN-GRU 短期电力负荷预测方法[J]. *电网技术*, 2019, 43(12): 4370-4376. ZHAO Bing, WANG Zengping, JI Weijia, et al. A short-term power load forecasting method based on attention mechanism of CNN-GRU[J]. *Power System Technology*, 2019, 43(12): 4370-4376.
- [22] 周满国,黄艳国,段锦锋. 基于 GRU-RF 模型的太阳辐照度短时预测[J]. *太阳能学报*, 2022, 43(7): 166-173. ZHOU Manguo, HUANG Yanguo, DUAN Jinfeng. Short term prediction of solar irradiance based on GRU-RF model[J]. *Acta Energetica Solaris Sinica*, 2022, 43(7): 166-173.
- [23] 刘文强,李涛. 基于改进蜣螂优化算法的无人机航迹规划[J]. *电子测量技术*, 2024, 47(15): 64-72. LIU Wenqiang, LI Tao. UAV trajectory planning based on enhanced dung beetle optimization algorithm[J]. *Electronic Measurement Technology*, 2024, 47(15): 64-72.
- [24] XUE J K, SHEN B. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization[J]. *The Journal of Supercomputing*, 2023, 79(7): 7305-7336.
- [25] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. *Advances in Engineering Software*, 2016, 95: 51-67.
- [26] 刘新宇,蒲欣雨,李继方,等. 基于贝叶斯优化的 VMD-GRU 短期风电功率预测[J]. *电力系统保护与控制*, 2023, 51(21): 158-165. LIU Xinyu, PU Xinyu, LI Jifang, et al. Short-term wind power prediction of a VMD-GRU based on Bayesian optimization[J]. *Power System Protection and Control*, 2023, 51(21): 158-165.