

基于GRU-MPC的光储充电站日前-日内两阶段优化控制

王 阳,刘希喆

(华南理工大学 电力学院,广东 广州 510641)

摘要:电动汽车负荷与光伏出力的随机性给光储充电站的经济运行带来严峻考验。为了更高效地利用储能系统以及提高控制策略的鲁棒性,建立光储充电站日前-日内两阶段优化模型。在日前阶段,结合变分模态分解与门控循环单元神经网络预测一天48个时刻的充电负荷,并建立以日充电成本最小为目标的优化模型;在日内阶段,以日前调度计划与日内实际运行结果的偏差最小为目标,采用模型预测控制来实现滚动优化,为了增强储能控制策略对不确定源荷的跟踪能力,在日内关键时间点结合超短期源荷预测的结果对日前计划进行更新,得到基于阶段性最佳参考轨迹的实时调度。以实际算例进行仿真计算,比较不同控制策略对充电成本的影响,结果表明所提两阶段优化控制策略可以节省更多的充电成本,有更高的经济价值。

关键词:充电站;日前优化;日内控制;变分模态分解;门控循环单元;模型预测控制

中图分类号:U 469.72

文献标志码:A

DOI:10.16081/j.epae.202208036

0 引言

近年来,随着能源短缺、气候变暖等能源环境问题的日益严峻,电动汽车EV(Electric Vehicle)行业得到了蓬勃发展,EV充电站的数量也日益增多^[1]。配置了光伏发电与储能系统的快充站在日照时段利用光伏发电满足部分日常负荷用电需求,基于分时电价,利用储能系统的“低储高放”获取最大的经济利益,通过“削峰填谷”平抑负荷波动,可在保证经济效益的同时促进节能减排。目前,对光储充电站的研究主要集中在优化容量配置与日前控制策略方面。文献[2-5]分别以投资成本与碳排放最小、电网出力曲线峰谷差减小、充电站经济效益最大作为优化目标,建立光储充电站容量配置模型,基于典型日或多场景负荷数据,利用粒子群、遗传算法等智能算法对模型进行求解,得到最优储能、光伏的容量配置。为了实现充电站每日的最优运营,提高储能的利用率,文献[6-8]在现有充电站配置的基础上建立储能日前优化模型,综合考虑充电站经济效益与储能系统的寿命损耗,求解出一日内储能系统的最优出力计划。日前计划能否适用于实际日的关键在于对日内负荷预测的准确性,由于负荷的经济敏感性,对负荷预测的较小偏差都会造成日内运行无法实现经济最优,因此,增强储能控制策略对不确定负荷的跟踪能力、实现光储充电站的日内滚动优化尤

为重要。

关于微电网日内滚动优化的研究主要集中在发电侧与电网侧,通常微电网的可控制量较多,调控空间较大,储能仅作为一种辅助手段用于配合多尺度的调控计划或促进新能源的消纳。文献[9]通过场景生成法生成大量源荷相关场景,利用场景相似度对源荷进行预测,以配电网期望运行成本最小为目标建立日前优化模型,并在日内阶段采用模型预测控制MPC(Model Predictive Control)对机组、储能、无功补偿装置等可调资源进行调控。文献[10]结合信息间隙决策理论IGDT(Information Gap Decision Theory)与MPC建立区域能源系统的双层能量优化模型,通过在日前调度采用鲁棒优化以及在日内阶段采用MPC滚动优化修正日前调度偏差,其中控制对象为燃气轮机、余热锅炉以及各类储能设备。文献[11]将高压配电网负荷转供与储能电站运行相协调,在日内阶段采用滚动优化来精准调控储能电站出力,达到降低避峰切负荷风险、消除阻塞、提高能源消纳水平的目的。光储充电站属于用户侧储能,主要的控制对象是储能系统,控制手段单一,实现精细化操控以及达到最优化的难度较大。

目前对光储充电站日内优化的研究较少。文献[12]对含多条公交线路的光储充电站进行日内优化,通过改进排队理论对公交车的充电需求进行预测,并利用滚动优化控制下一时段的储能出力以降低车站的运营成本,但其仅考虑公交车的充电,而未对随机性更强的家用EV的充电需求进行分析。文献[13]提出一种基于深度强化学习的光储充电站储能系统全寿命周期优化运行方法,在日内调控阶段考虑需求、光伏与电价的不确定性,并采用双延迟深度确定性策略梯度算法进行求解,但是深度学习需要大量的数据进行预学习以及训练,在实际运行中

收稿日期:2022-05-07;修回日期:2022-08-19

在线出版日期:2022-08-24

基金项目:国家自然科学基金委员会-国家电网公司智能电网联合基金资助项目(U2066212)

Project supported by the Joint Fund of the National Natural Science Foundation of China-Smart Grid of State Grid Corporation of China(U2066212)

可能难以实现。

基于上述研究,为了充分发挥储能与光伏系统的作用,实现充电站最优经济效益运行,本文建立光储充电站日前-日内两阶段优化控制模型。在日前优化阶段,综合考虑各类电费成本以及储能寿命损耗,建立以充电站日成本最低为目标的优化模型,并基于历史负荷数据结合变分模态分解VMD (Variational Mode Decomposition)与门控循环单元GRU (Gate Recurrent Unit) (记为VMD-GRU)神经网络对后一日的负荷进行预测,基于此,通过日前优化模型得到日前经济最优调度计划。在日内阶段,以日前调度计划作为参考轨迹,采用MPC进行滚动优化,并结合充电站能量管理系统能够预测站内超短期负荷的特点,在关键时间点対日前调度计划进行更新,使得参考轨迹更接近真实值。最后基于实际充电站算例,设计3种控制方案进行比较,结果表明本文提出的两阶段控制策略具有最好的经济效益。

1 基于VMD-GRU神经网络的充电站负荷预测

GRU神经网络是在长短期记忆LSTM (Long Short-Term Memory)神经网络模型的基础上提出的,与LSTM神经网络相比,GRU神经网络的训练参数较少,其保持了与LSTM神经网络接近的预测效果,并且解决了传统时序神经网络中容易出现的梯度爆炸问题,在电力负荷等长时间序列的预测方面应用广泛^[14]。GRU神经网络的模型结构图如附录A所示。

根据历史数据对未来时段的负荷进行预测属于回归任务,因此,本文选取均方误差MSE (Mean Square Error)作为神经网络的损失函数,具体公式为:

$$\varepsilon_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N (f_i - y_i)^2 \quad (1)$$

式中: ε_{MSE} 为MSE; N 为样本总数; f_i 、 y_i 分别为第 i 个样本的预测值与实际值。

电力负荷具有随机性、波动性的特点,单一神经网络往往无法对其中的规律性进行很好的拟合,因此,本文提出采用VMD对负荷信号进行预处理。VMD是一种自适应、完全非递归的模态变分和信号处理方法,可以降低复杂度高和非线性强的时间序列非平稳性,发现时间序列在不同时间尺度下的变化规律。本文采用VMD将复合序列分解为多个子序列,对于每个子序列都采用GRU神经网络进行预测,再将预测结果重构生成最终的负荷数据。考虑到预测算法存在多种超参数,本文增加粒子群优化算法进行参数寻优。

2 光储充电站运行模型

2.1 储能系统

储能电池被广泛应用于智能电网与分布式发电系统的建设中,在发电、输电与配电方面都起到了巨大的作用^[15]。储能系统主要由电池电堆、储能变流器系统和电池管理系统组成。储能电池通过当前时刻的运行状态和剩余容量状态确定下一时刻的充、放电功率和运行模式。储能电池的输入、输出功率与损耗计算如下:

$$P_{\text{eff}}^{\text{ch}}(t) = (P_{\text{in}}(t)\eta_{\text{inv}}(t) - P_{\text{idl}})\eta_{\text{ch}} \quad (2)$$

$$P_{\text{eff}}^{\text{dch}}(t) = \frac{P_{\text{out}}(t)}{\eta_{\text{inv}}(t)\eta_{\text{dch}}} + \frac{P_{\text{idl}}}{\eta_{\text{dch}}} \quad (3)$$

$$S_{\text{soc}}(t+1) = S_{\text{soc}}(t) \pm P_{\text{eff}}^{\text{ch,dch}}(t)\Delta t \quad (4)$$

式中: $P_{\text{eff}}^{\text{ch}}(t)$ 、 $P_{\text{eff}}^{\text{dch}}(t)$ 分别为 t 时刻电池实际的有效充、放电功率; $P_{\text{in}}(t)$ 、 $P_{\text{out}}(t)$ 分别为 t 时刻电网输入储能系统与储能系统输出至电网的功率; P_{idl} 为电池的空转损耗,一般设为额定功率的1%; η_{ch} 、 η_{dch} 分别为充、放电能量效率; $\eta_{\text{inv}}(t)$ 为 t 时刻逆变器的转换效率; $S_{\text{soc}}(t)$ 为 t 时刻的电池电量; $P_{\text{eff}}^{\text{ch,dch}}(t)$ 表示 $P_{\text{eff}}^{\text{ch}}(t)$ 或 $P_{\text{eff}}^{\text{dch}}(t)$; Δt 为时间间隔。

2.2 光伏系统

光伏发电系统一般由太阳能电池方阵、逆变器、交流配电柜、太阳跟踪控制系统等设备组成。光伏阵列的直流功率输出与当地的光照幅值、温度变化有关^[16],即:

$$P_{\text{PV}}(t) = P_{\text{pmpp}} P_1(t) P_T(t) \eta_{\text{eff}} \quad (5)$$

式中: $P_{\text{PV}}(t)$ 为 t 时刻光伏系统的交流出力; P_{pmpp} 为在25℃、1kW/m²光照下最大出力基准值; $P_1(t)$ 为 t 时刻与1kW/m²对应的光照幅值比例因子; $P_T(t)$ 为 t 时刻与25℃对应的温度特性比例因子; η_{eff} 为逆变器的转换效率。

3 日前-日内经济优化模型

3.1 日前优化模型

1) 目标函数。

模型的目标函数为光储充电站的日内运行总成本最小,其中包括充电电费、固定电费与储能投资成本。控制每个时刻储能的充、放电功率,使储能的经济效益达到最大,并利用雨流计数法将储能的寿命年限与储能投资成本结合并折算为储能系统总投资成本。计算公式如式(6)~(8)所示。

$$\min f = \sum_{t=1}^D C_p^t + C_{\text{c,d}} + C_{\text{sum,d}} \quad (6)$$

$$C_{\text{c,d}} = \frac{P_{\text{max}} C}{\eta \times 30} \quad (7)$$

$$C_{\text{sum}} = (C_E E_m + C_p P_m + \gamma_s)(1 + \mu) \quad (8)$$

式中: f 为光储充电站的日内运行总成本; D 为日内

总时刻数; C_p 为 t 时刻充电站消耗电能产生的电费; $C_{c,d}$ 、 $C_{sum,d}$ 分别为折算至每天的固定电费和储能电池在寿命周期内的投资成本。固定电费由所选变压器的容量所决定,为了简化计算,将充电站消耗的最大时刻功率除以系数 η ($\eta=0.8$) 表示变压器容量; C 为固定电价,根据充电站用电规模取不同的值; C_{sum} 为储能系统总投资成本,由配置容量成本、配置功率成本与固定投资成本构成; C_E 、 C_p 分别为单位容量与功率的配置价格; E_m 、 P_m 分别为储能的额定容量与额定功率; γ_s 为固定投资; μ 为由更换零部件产生的额外成本系数。考虑到储能电池的使用年限通常较长,直接用总投资成本进行折算容易造成偏差,因此,本文采用资本回收系数进行修正^[16],折算后的日投资成本为:

$$C_{sum,d} = \frac{C_{sum}\beta + C_i}{365} \quad (9)$$

$$\beta = \frac{r(r+1)}{(r+1)^L - 1} \quad (10)$$

式中: β 为资本回收系数,表示规划周期内储能的初始投资成本等效价值; C_i 为运维成本的年值; r 为贴现率; L 为储能系统的寿命年限,可以结合雨流计数法和电池的循环寿命曲线得到。

2) 约束条件,即:

$$S_{soc,min} \leq S_{soc}(t) \leq S_{soc,max} \quad (11)$$

$$0 \leq P_{eff}^{ch}(t), P_{eff}^{dch}(t) \leq P_m \quad (12)$$

式中: $S_{soc,min}$ 、 $S_{soc,max}$ 分别为储能电池电量的最小值与最大值,分别为额定满电量的 10% 和 90%。

为了保障储能电池的安全运行,每个时刻电池的容量与充、放电功率均需要限制在规定的范围内,即:

$$0 \leq P_{cs}(t) = P_{EV}(t) - P_{in,out}(t) - P_{PV}(t) \leq P_{max} \quad (13)$$

$$0 \leq P_{PV}(t) \leq P_{PV,max} \quad (14)$$

式中: $P_{cs}(t)$ 为 t 时刻台区净负荷; $P_{EV}(t)$ 为 t 时刻 EV 充电负荷; $P_{in,out}(t)$ 表示 $P_{in}(t)$ 或者 $P_{out}(t)$; P_{max} 为设定的充电站台区最大负荷; $P_{PV,max}$ 为光伏系统最大出力。为了避免因储能电池的放电功率大于 EV 充电负荷而造成潮流逆转,以及因台区负荷越限而不利变压器经济运行的经济运行,需要对充电站台区的总体负荷进行约束。

3.2 日内滚动优化模型

3.2.1 MPC 优化

EV 充电需求与光伏出力具有不确定性且光储充电站属于用户侧微电网,控制对象与控制方法较少,日前调度计划与日内的实际运行情况往往存在一定偏差,若按照日前计划进行储能控制,则无法达到经济最优甚至会造成亏损,因此本文设计基于 MPC 的日内滚动优化模型。MPC 具有一定的预测系统未来动态行为的能力,可以有效克服过程的不确定性,在

日内实际运行中保证模型运行的经济性^[17-18]。

MPC 的基础是设定预测模型,考虑到光储充电站的优化调度属于含非线性、不确定性的多输入、输出问题,将状态空间表达式作为预测模型,具体的状态空间表达式为:

$$\mathbf{x}_m(k+1) = \mathbf{A}\mathbf{x}_m(k) + \mathbf{B}\mathbf{u}(k) + \mathbf{C}\mathbf{r}(k) \quad (15)$$

$$\mathbf{y}(k) = \mathbf{D}\mathbf{x}_m(k) \quad (16)$$

式中: k 为预测时域的时刻; $\mathbf{x}_m(k) = [S_{soc}(k), P_{cs}(k+1), P_{eff}^{ch,dch}(k+1), P_{EV}(k+1)]^T$ 为 k 时刻的状态变量,包括储能电池电量、台区净负荷、储能电池功率以及 EV 充电负荷; 设置储能功率变化量 $\mathbf{u}(k) = \Delta P_{eff}^{ch,dch}(k)$ 为 k 时刻的控制变量; $\mathbf{r}(k) = [\Delta P_{EV}(k), \Delta P_{PV}(k)]^T$ 为 k 时刻的扰动量,包括 EV 充电负荷增量以及光伏出力增量; $\mathbf{y}(k) = [S_{soc}(k), P_{cs}(k)]^T$ 为 k 时刻模型的输出量,包括储能电池电量以及台区净负荷; $\mathbf{A}$ 、 $\mathbf{B}$ 、 $\mathbf{C}$ 、 $\mathbf{D}$ 分别为系统矩阵、输入矩阵、扰动矩阵与输出矩阵。

确定预测模型后,根据当前所测得的状态信息对模型未来的动态进行预测,并得到预测时域 n 内每个采样时刻的系统状态 $[\mathbf{y}(k+1), \mathbf{y}(k+2), \dots, \mathbf{y}(k+n)]^T$, 然后以预测时域内系统状态与期望偏差最小为目标函数进行开环优化,求解得到控制变量的时间序列 $[\mathbf{u}(k), \mathbf{u}(k+1), \dots, \mathbf{u}(k+n-1)]^T$, 并选择 $\mathbf{u}(k)$ 作为实际输入。

将目标函数写为二次规划的形式,其中包括误差加权和、输入加权和与终端误差项,即:

$$\min \left[\sum_{k=1}^{n-1} (\mathbf{E}^T(k) \mathbf{Q} \mathbf{E}(k) + \mathbf{u}^T(k) \mathbf{R} \mathbf{u}(k)) + \mathbf{E}^T(n) \mathbf{F} \mathbf{E}(n) \right] \quad (17)$$

$$\mathbf{E}(k) = \mathbf{x}_m(k) - \mathbf{x}_m^{ref}(k) \quad (18)$$

式中: $\mathbf{x}_m^{ref}(k)$ 为 k 时刻与状态变量相对应的日前优化期望值; $\mathbf{E}(k)$ 为 k 时刻状态变量与期望值之间的误差; $\mathbf{E}(n)$ 为预测时域的终端项误差; $\mathbf{Q}$ 、 $\mathbf{R}$ 分别为误差与输入的调节矩阵; $\mathbf{F}$ 为终端误差权重矩阵,用于调节状态矩阵与输入矩阵中多个状态量与输入量对控制输出的影响程度。

3.2.2 基于关键时刻更新的优化机制

传统的 MPC 通过将控制序列中的第 1 项作为系统输入以及在每次采样的初期将状态矩阵的初始值更新为状态量的实际测量值完成反馈矫正,在时域上不断迭代进行滚动优化,具有一定的鲁棒性与稳定性。但 MPC 的控制效果仍然取决于参考轨迹的选择,当日内实际的负荷变化与参考轨迹差别较大时,最终的控制结果也会有较大误差,不能达到经济最优。因此,本文结合光储充电站管理系统,根据站内实时的充电 EV 数量、充电情况对短期 EV 负荷进行精确预测,设计一种在关键时间点更新参考轨迹的方法,将站内超短期负荷预测的结果与日前预测

结果相结合,并将新生成的负荷数据代入日前控制模型来生成新的参考轨迹。EV负荷与光伏出力的短期负荷更新公式为:

$$P'_{EV}(t'+T) = \sum_{s=1}^S P_s(t'+T) + \varepsilon \quad (19)$$

$$P'_{PV}(t'+T) = P_{pmpp} P_I(t'+T) P_T(t'+T) \eta_{eff} \quad (20)$$

式中: $P'_{EV}(t'+T)$ 、 $P'_{PV}(t'+T)$ 分别为预测时域 T 内的更新预测负荷与光伏出力, t' 为关键时间点; $P_s(t'+T)$ 为充电桩 s 在预测时域内的计划充电功率; S 为充电桩总数; ε 为均匀分布的测量误差。预测时域内的温度与光照信息由天气预报得到。

利用关键时间点进行更新,有效避免了每个采样时刻参考轨迹都变化所造成的控制效果保守的问题。具体的算法流程图如图1所示。




图1 算法流程图


Fig.1 Algorithm flowchart

4 算例分析


4.1 基于VMD-GRU神经网络的负荷预测结果

在日前负荷预测方面,将我国华南某地区两年间每天48个采样点的EV充电负荷作为实验样本数据集,共35040个采样点。首先利用VMD将负荷时间序列进行分解,设置模态分解个数为5,分解结果如图2所示。

由图2可以看出, IMF_1 与 IMF_2 分量体现了负荷在长时间尺度下的变化规律, IMF_3 — IMF_5 分量体现了负荷在较短时间尺度下的变化规律,因此采用VMD可以更清晰地提取时间序列的变化规律。



(a) 长期分量



(b) 短期分量

图2 VMD结果图

Fig.2 Diagram of VMD results

将标准化处理后的负荷分解数据按7:2:1的比例分为训练集、测试集和验证集。为了实现通过前7 d的负荷预测后1 d的负荷,以前7 d中7×48个时刻与后1 d中48个时刻的数据构建时间滑窗。利用GRU神经网络进行训练,每次迭代的样本批次为32,节点数为64,学习率设置为0.001,选用Adam算法进行梯度优化,最终得到不同网络预测的日负荷曲线,如图3所示。不同神经网络的性能比较如表1所示,表中RMSE、MAPE分别为均方根误差和平均绝对百分比误差。

由图3可知,VMD-GRU神经网络对负荷预测有着较好的表现,其预测曲线与实际值的整体相似程度




图3 不同神经网络的预测曲线

Fig.3 Prediction curves of different neural networks

表 1 不同神经网络性能比较
Table 1 Performance comparison of different neural networks

神经网络	RMSE	全时段 MAPE / %	高峰时段 MAPE / %	训练时 间 / h
VMD-GRU	54.78	34.7	9.5	1.08
CNN-GRU	64.36	35.5	14.8	2.20
XGboost	55.79	35.4	15.4	0.42
CNN	69.09	37.6	20.2	1.20
LSTM	58.27	36.6	18.2	1.80

较高,准确捕捉到了时序负荷序列的典型规律特征与随机波动。结合表 1 可知,VMD-GRU 神经网络的负荷预测效果最优,尤其是负荷高峰时段(10:00—12:00、18:00—21:00)的负荷预测效果,这说明 VMD 可以较好地提取负荷高峰时段的负荷变化规律,也更有利于后续日内控制对储能进行提前存储等动作。CNN-GRU 神经网络与 XGboost 的负荷预测效果次优,其全时段 MAPE 与 VMD-GRU 神经网络的相差不大,但这 2 种神经网络对负荷高峰时段的负荷预测效果稍差。CNN 的负荷预测效果最差,这是因为 CNN 适用于处理多维数据,对 1 维时间序列的预测能力不如其他网络。

4.2 日前优化结果分析

根据当地的负荷需求情况,以一座有 10 个充电桩的快充光储充电站作为算例进行分析,每个充电桩的快充功率为 120 kW,储能容量为 1 300 kW·h。考虑到充电站屋顶面积的限制,光伏系统容量为 50 kW。为了避免多次存储造成功率损耗,光伏系统采取“自发自用”的策略,不考虑储能存储光伏电能,日前模型的光伏出力由预测的天气数据换算得到。除去从存储介质向电能转换相关的充、放电损耗后,储能电池的平均充、放电能量效率为 90%,逆变器的转换效率为 95%,储能系统整体充、放电效率为 73%。储能系统的配置价格为 4 500 元 / (kW·h)。选取 2019 年 5 月 5 日的预测负荷作为日前控制模型的负荷数据,日前与日内优化模型均采用 YALMIP 软件包中的 CPLEX 求解器进行求解,模型的优化结果如图 4 所示。

由图 4 可知,分时电价为储能日前优化中最主要的导向因素,储能系统在夜间电价较低的时段进行充电,在电价最高的 11:00、15:00—16:00 进行放电,以获得最高的经济利益,同时为了弥补电池容量的不足,选择在午间电价稍低的时段进行二次充电。在减少固定电费方面,日前计划中综合考虑储能充电导致的站内净负荷攀升与 EV 峰值负荷,对该日内充电站的峰值负荷进行一定的削减。最终,经过日前优化,该日充电电费共节省 18.4%,约为 999 元,固定电费节省 18.9%,约为 139.2 元,结合储能折算成本,该日净收益为 337.1 元。





图 4 日前优化结果
Fig.4 Day-ahead optimization results

4.3 日内优化结果分析

在日内优化阶段,本文设置 3 种方案进行对比:方案 1,利用 CNN-GRU 神经网络预测数据生成日前控制计划,在此基础上进行 MPC 日内滚动优化;方案 2,利用 VMD-GRU 神经网络预测数据生成的参考轨迹进行 MPC 日内滚动优化;方案 3,在方案 2 的基础上增加关键节点负荷更新操作。MPC 预测时域为 2 h,时间分辨率为 30 min,站内能量系统负荷预测时域为 1.5 h,以 08:00、11:00、14:00、18:00 作为关键时间点。最优方案与 3 种对比方案运行后的站内净负荷对比曲线如图 5 所示,其中最优方案是指在实际充电负荷与光伏出力已知的情况下运行日前模型得到的最优方案。方案 1—3 的净负荷曲线与最优负荷的误差如表 2 所示。

由图 5 与表 2 可知:方案 1 的控制效果最差,这是因为预测日负荷与实际日负荷在负荷高峰与高价时段有一定差异,按照预测日的数据进行调控不




图 5 日内优化结果
Fig.5 Intra-day optimization results

表2 不同方案的负荷误差

Table 2 Load error of different schemes

方案	全时段 MAPE / %	高电价时段 MAPE / %	峰值负荷 误差 / %
1	22	7.8	14.3
2	14	5.8	8.7
3	11	3.7	6.5

仅在高电价时段没有最大限度放出来将负荷削减到最低,而且在19:00—21:00的负荷高峰时段对峰值负荷的抑制效果也较差,同时由于对未来负荷预测得不够准确,二次充电时“峰上加峰”带来的新的峰值负荷影响了日内经济运行;相较于方案1,方案2有更好的优化效果,但是由于预测日负荷与实际日负荷间存在一定误差,最终的控制效果无法达到最优;相较于方案2,方案3的净负荷曲线与最优方案的曲线最为相似,其全时段与高电价时段的MAPE均为最低,这是因为方案3加入了站内超短期负荷预测操作,并在关键时间点对参考轨迹进行了更新,使得其在日内的参考轨迹均最接近真实值,相较于方案1和方案2,其峰值负荷误差最小,高电价时段放出的电量最多。为了进一步分析3种方案的经济效益,表3给出了各类成本效益数据,其中贴现率 $r=0.03$ 。

表3 各类成本效益数据

Table 3 Various cost-benefit data

方案	电量电费 / 元	折算固定 电费 / 元	电池日折算 成本 / 元	运行期间日 收益 / 元
1	4449.4	679.9	801.3	226.3
2	4446.3	646.5	803.0	261.1
3	4436.0	636.2	798.0	286.7
理想情况	4423.7	594.7	801.3	337.2
未优化情况	5423.0	733.9		

由表3可知:方案1的优化效果最差,其在二次充电时的充电功率过大,导致负荷攀升,从而出现了较大的峰值负荷,因此折算固定电费较高;方案2的整体经济优化水平较为中庸,该方案虽然有一定的反馈机制,但是未深入地与实际源荷情况相结合,导致鲁棒性不足;相较于方案1与方案2,方案3在电量电费、折算固定电费和电池日折算成本方面均有更好的经济效益,其运行期间日收益比前2种方案分别增加26.7%与9.8%,优化效果与理想情况最接近,运行期间日收益约为理想情况的85.0%。

5 结论

EV充电负荷与光伏出力具有很强的随机性与不确定性,为了减少预测误差造成的调控运行偏差所带来的经济损失,本文利用VMD-GRU神经网络对后一日的负荷进行预测,在日内根据站内实时的充电状态对预测负荷进行精准更新,并综合各类成

本建立经济最优的光储充电站日前-日内两阶段优化控制模型,仿真分析得到了以下结论。

1)结合历史负荷数据,通过VMD-GRU神经网络对后一日的EV充电负荷进行预测,所得预测值与实际值偏差较小,在峰值负荷的预测上有较好的效果。

2)本文建立充电站两阶段优化控制模型,在日前阶段综合考虑电量电费、固定电费与电池成本,结合精准的负荷预测算法,最终的结果为日内阶段提供了较好的参考轨迹。在日前优化的基础上,日内阶段采用基于关键时间点更新轨迹的MPC对储能系统进行滚动优化控制。与其他控制策略的仿真结果对比表明,本文所提策略可以节省最多的充电成本,为日后的实际运营提供了理论参考。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 王毅,陈进,麻秀,等. 采用分群优化的电动汽车与电网互动调度策略[J]. 电力自动化设备,2020,40(5):77-85.
WANG Yi, CHEN Jin, MA Xiu, et al. Interactive scheduling strategy between electric vehicles and power grid based on group optimization[J]. Electric Power Automation Equipment, 2020,40(5):77-85.
- [2] 李景丽,时永凯,张琳娟,等. 考虑电动汽车有序充电的光储充电站储能容量优化策略[J]. 电力系统保护与控制,2021,49(7):94-102.
LI Jingli, SHI Yongkai, ZHANG Linjuan, et al. Optimization strategy for the energy storage capacity of a charging station with photovoltaic and energy storage considering orderly charging of electric vehicles[J]. Power System Protection and Control, 2021,49(7):94-102.
- [3] 杨健维,李爱,廖凯. 城际高速路网中光储充电站的定容规划[J]. 电网技术,2020,44(3):934-943.
YANG Jianwei, LI Ai, LIAO Kai. Capacity planning of light storage charging station for intercity highways based on charging guidance[J]. Power System Technology, 2020,44(3):934-943.
- [4] 刘国明,于晖,康凯,等. 考虑需求响应与碳排放的光储充电站容量配置[J]. 电力系统及其自动化学报,2021,33(7):106-112.
LIU Guoming, YU Hui, KANG Kai, et al. Capacity allocation of PV-storage-charging station considering demand response and carbon emissions[J]. Proceedings of the CSU-EPSCA, 2021, 33(7):106-112.
- [5] 李笑彤,宋宝同,吕风波,等. 基于负荷数据聚类的充电站储能容量规划方法[J]. 电网与清洁能源,2021,37(1):90-96.
LI Xiaotong, SONG Baotong, LÜ Fengbo, et al. An energy storage capacity planning method of charging station based on load data clustering[J]. Power System and Clean Energy, 2021,37(1):90-96.
- [6] 侯慧,王逸凡,黄亮,等. 满足电动汽车快充需求的含储能复合型充电站充电优化策略[J]. 电力自动化设备,2022,42(1):65-71.
HOU Hui, WANG Yifan, HUANG Liang, et al. Charging optimization strategy of composite charging station with energy storage to meet fast charging demand of electric vehicles[J]. Electric Power Automation Equipment, 2022,42(1):65-71.
- [7] 吴凡,周云,冯冬涵,等. 光储充一体化快充站日前运行策略

- [J]. 电测与仪表, 2021, 58(12): 104-109.
- WU Fan, ZHOU Yun, FENG Donghan, et al. Day-ahead scheduling strategy of fast charging station with battery energy storage system and PV[J]. Electrical Measurement & Instrumentation, 2021, 58(12): 104-109.
- [8] 罗恒, 严晓, 王钦, 等. 充电站光储充控制策略[J]. 储能科学与技术, 2022, 11(1): 275-282.
- LUO Heng, YAN Xiao, WANG Qin, et al. Charging and discharging strategy of battery energy storage in the charging station with the presence of photovoltaic[J]. Energy Storage Science and Technology, 2022, 11(1): 275-282.
- [9] 刘自发, 张婷, 王岩. 基于模型预测控制的主动配电网多场景变时间尺度优化调度[J]. 电力自动化设备, 2022, 42(4): 121-128.
- LIU Zifa, ZHANG Ting, WANG Yan. Multi-scenario variable time scale optimal scheduling of active distribution network based on model predictive control[J]. Electric Power Automation Equipment, 2022, 42(4): 121-128.
- [10] 孔德政, 张靖, 何宇, 等. 区域综合能源系统 IGDT-MPC 双层能量优化调度[J/OL]. 电网技术. [2022-05-03]. <https://doi.org/10.13335/j.1000-3673.pst.2021.1794>.
- [11] 曾宇, 刘友波, 高红均, 等. 基于模型预测控制的高压配电网负荷转供与储能电站协同运行[J]. 电网技术, 2021, 45(5): 1902-1911.
- ZENG Yu, LIU Youbo, GAO Hongjun, et al. Load transfer capability of HV distribution network and coordinated operation with energy storage power station based on model predictive control[J]. Power System Technology, 2021, 45(5): 1902-1911.
- [12] 杨祺铭, 季陈林, 刘友波, 等. 多条公交线路的光储充电站日内滚动优化策略[J]. 智慧电力, 2020, 48(8): 44-50, 90.
- YANG Qiming, JI Chenlin, LIU Youbo, et al. Day-rolling optimization strategy for photovoltaic-energy storage charging station with multiple electric bus lines[J]. Smart Power, 2020, 48(8): 44-50, 90.
- [13] 陈亭轩, 徐潇源, 严正, 等. 基于深度强化学习的光储充电站储能系统优化运行[J]. 电力自动化设备, 2021, 41(10): 90-98.
- CHEN Tingxuan, XU Xiaoyuan, YAN Zheng, et al. Optimal operation based on deep reinforcement learning for energy storage system in photovoltaic-storage charging station[J]. Electric Power Automation Equipment, 2021, 41(10): 90-98.
- [14] VEERAMSETTY V, REDDY K R, SANTHOSH M, et al. Short-term electric power load forecasting using random forest and gated recurrent unit[J]. Electrical Engineering, 2022, 104(1): 307-329.
- [15] 张明霞, 闫涛, 来小康, 等. 电网新功能形态下储能技术的发展愿景和技术路径[J]. 电网技术, 2018, 42(5): 1370-1377.
- ZHANG Mingxia, YAN Tao, LAI Xiaokang, et al. Technology vision and route of energy storage under new power grid function configuration[J]. Power System Technology, 2018, 42(5): 1370-1377.
- [16] JAN-NGURN C, BHUMKITTIPICH K. Integration of solar and wind power sources in power grid with energy storage system using discrete balancing[C]//2021 9th International Electrical Engineering Congress. Pattaya, Thailand: IEEE, 2021: 201-204.
- [17] FORTENBACHER P, ULBIG A, ANDERSSON G. Optimal placement and sizing of distributed battery storage in low voltage grids using receding horizon control strategies[J]. IEEE Transactions on Power Systems, 2018, 33(3): 2383-2394.
- [18] GHANAATIAN M, LOTFIFARD S. Control of flywheel energy storage systems in the presence of uncertainties[J]. IEEE Transactions on Sustainable Energy, 2019, 10(1): 36-45.

作者简介:



王 阳

王 阳(1998—),男,硕士研究生,研究方向为含新能源的配电网运行优化(E-mail: 2824290078@qq.com);

刘希喆(1970—),男,副研究员,主要研究方向为配电网智能运行与优化(E-mail: liuxizhe@scut.edu.cn)。

(编辑 王锦秀)

Day-ahead and intra-day two-stage optimal control of photovoltaic-energy storage charging station based on GRU-MPC

WANG Yang, LIU Xizhe

(School of Electric Power Engineering, South China University of Technology, Guangzhou 510641, China)

Abstract: The randomness of electric vehicle load and photovoltaic output brings severe test to the economic operation of photovoltaic-energy storage charging station. In order to use the energy storage system more efficiently and improve the robustness of control strategy, a day-ahead and intra-day two-stage optimization model for photovoltaic-energy storage charging station is built. In the day-ahead stage, the variational mode decomposition and gate recurrent unit neural network are combined to predict the charging load at 48 moments of a day, and an optimization model with the minimum daily charging cost as its object is established. In the intra-day stage, the model predictive control is adopted to achieve rolling optimization with the minimum deviation between the day-ahead scheduling plan and the intra-day practical operation results as its object, in order to enhance the tracking ability of energy storage control strategy to uncertain sources and loads, the day-ahead plan is updated combining with the results of ultra short-term source and load prediction at the key intra-day moments, and the real-time scheduling based on staged optimal reference trajectory is obtained. The simulation and calculation are carried out with a practical example, the effect of different control strategies on the charging cost are compared, and results show that the proposed two-stage optimal control strategy can save more charging costs and has higher economic value.

Key words: charging station; day-ahead optimization; intra-day control; VMD; GRU; MPC

附录 A




图 A1 GRU 神经网络模型结构图
Fig.A1 Structural diagram of GRU neural network model

不同于 LSTM 引入的遗忘门、输入门和输出门 3 种门控结构，GRU 神经网络只有更新门与重置门 2 种。更新门用于控制前一时刻的状态信息被带入到当前状态中的程度，更新门的值越大说明前一时刻的状态信息带入越多。重置门控制前一状态有多少信息被写入到当前的候选状态 $\tilde{h}_t$ 上，重置门越小，前一状态的信息被写入得越少。网络的具体计算公式为：

$$z_t = \sigma(\mathbf{W}_z[h_{t-1}, x_t]) \quad (\text{A1})$$

$$r_t = \sigma(\mathbf{W}_r[h_{t-1}, x_t]) \quad (\text{A2})$$

$$\tilde{h}_t = \tanh(\mathbf{W}[r_t h_{t-1}, x_t]) \quad (\text{A3})$$

$$h_t = (1 - z_t)h_{t-1} + z_t \tilde{h}_t \quad (\text{A4})$$

式中： z_t 与 r_t 分别为更新门与重置门； x_t 为输入； h_t 为 t 时刻的状态信息； σ 为激活函数 sigmoid； $\mathbf{W}_z$ 与 $\mathbf{W}_r$ 分别为更新门与重置门输入量的权重矩阵； $\mathbf{W}$ 为状态权重矩阵。