

基于特征分解的虚拟电厂运行负荷预测方法研究

潘 翀,郝文斌,谢 波,孟志高,何凌云,卫佳奇
(国网四川省电力公司成都供电公司,四川 成都 610041)

摘要:虚拟电厂是将各种分布式能源资源相聚合作为一种高效电厂的能源管理系统,其能够根据电力系统需求进行快速响应,并能降低电力系统运行成本、提高电力系统的整体可靠性和稳定性。然而,由于虚拟电厂的用电负荷具有波动性、随机性、季节性及峰谷差异显著等特征,给虚拟电厂电力供应管理带来了挑战。为解决上述问题,提出了一种基于特征分解的虚拟电厂运行负荷预测方法,这对虚拟电厂的电力的调度和需求响应提供信息支撑。首先,使用局部加权散点平滑法的季节趋势分解方法捕捉虚拟电厂负荷数据的趋势、季节性变化特征,得到历史负荷资源特征数据;然后,结合历史负荷资源数据和外部影响因素构建基于长短期记忆网络负荷预测模型;最后,应用虚拟电厂运行数据进行实验验证。结果表明,所提方法的决定系数 R^2 为 0.98,能够实现电厂负荷精准预测。

关键词:虚拟电厂;分布式能源资源;负荷预测;长短期记忆网络;特征分解

中图分类号:TM 73 **文献标志码:**A **文章编号:**1003-6954(2025)02-0001-07

DOI:10.16527/j.issn.1003-6954.20250201

Research on Operating Load Forecasting Method for Virtual Power Plants Based on Feature Decomposition

PAN Chong, HAO Wenbin, XIE Bo, MENG Zhigao, HE Lingyun, WEI Jiaqi
(State Grid Chengdu Electric Power Supply Company, Chengdu 610041, Sichuan, China)

Abstract: Virtual power plants (VPPs) integrate various distributed energy resources to create an efficient energy management system, which can swiftly respond to the demands of power grid, reduce operational costs and enhance the overall reliability and stability of power supply. However, the management of power supply in VPPs is challenged by the volatility, stochasticity, seasonality and substantial peak-valley variations inherent in electricity load dynamics. To address these challenges, an operating load forecasting method for virtual power plants based on feature decomposition is proposed, which provides essential information support for both power dispatching and demand response within VPPs. Firstly, seasonal-trend decomposition using LOESS (STL) is employed to capture trend and seasonal variation characteristics in virtual power plant load data, thereby extracting historical load resource features. Secondly, a load forecasting model based on long short-term memory (LSTM) network is developed by integrating historical load resource data with external influencing factors. Finally, experimental verification is carried out using operational data from virtual power plants. The results show that the determination coefficient R^2 of the proposed method is 0.98, which can accurately predict the power plant load.

Key words: virtual power plant; distributed energy resources; load forecasting; long short-term memory; feature decomposition

0 引言

随着生态环境的恶化,中国提出了于 2030 年实现碳达峰、2050 年实现碳中和的宏伟目标^[1]。在此

基金项目:国网四川省电力公司科技项目“新型电力系统背景下虚拟电厂控制策略及运行方法研究”(521904240005)

背景下,新能源逐渐成为新型电力系统的主要发展方向和核心电力来源。然而,由于风能和太阳能等新能源具有间歇性和不确定性,导致其在电力供应过程中存在波动性和不可预测性,给电力系统的稳定运行带来了挑战^[2]。虚拟电厂以其能够整合和优化分布式能源资源、提高电力系统灵活性和响应速度的特性,为解决上述问题提供了一种创新且有

效的方案^[3]。通过分布式能源资源的聚合和链接,虚拟电厂能够将分散的风能、太阳能发电装置、储能系统、可控负荷以及电动汽车等多种分布式资源聚合成一个可统一调度和管理的虚拟整体。这样不仅可以实现对新能源发电量的实时预测和动态调节,确保电力供需的平衡和稳定;还能在新能源发电过剩时通过储能和负荷调节等手段,有效吸纳并储存多余电量,待需求高峰时再释放,从而大幅提升能源利用效率,促进新能源的可持续发展^[4]。

当前,为提高虚拟电厂的电力利用效率,对其用电负荷预测展开了大量研究。首先,为了解决储能配置有限导致的可调容量不足、光伏短时出力难以精确预测以及功率分配不合理等问题,文献[5]提出了一种基于随机模型预测控制的虚拟电厂二次调频策略。该策略通过聚合多种分布式能源资源,实现了对电力系统需求的快速、准确响应,并显著降低了功率调节对系统内部电压的不良影响。与此同时,为了更深入地分析挖掘分布式资源与电力系统之间的交互活跃程度,文献[6]提出了一种基于长短期记忆网络(long short-term memory, LSTM)的短期混合信息流预测模型。该模型能够综合考虑多种外部因素,对分布式能源的出力情况进行精准预测,从而有效提高了系统的控制效率和能源利用效率。此外,虚拟电厂能够将需求侧资源和分布式能源与传统电网进行深度融合。然而,随着虚拟电厂规模的扩大和应用的深入,电能质量与可靠性问题成为制约其发展的关键因素。为此,文献[7]通过聚类分析和关联度分析方法对负荷进行精准预测,为虚拟电厂的需求响应、清洁能源消纳等业务提供了有力支撑。随着智能终端的异构连接和海量数据的接入,传统虚拟电厂的运行管理需求已经远远超出了云计算技术的处理能力。因此,文献[8]将边缘计算技术引入到虚拟电厂的运行管理中,提出了基于边缘计算的虚拟电厂架构及光伏出力预测方法。该方法通过在网络边缘侧进行数据处理和分析,有效提高了系统的实时性和协同性能。另外,为了解决虚拟电厂中光伏不确定性数据挖掘的难题,文献[9]还引入了条件生成对抗网络和变分自编码器。这两种方法能够提取虚拟电厂的不确定性特征,并实现对光伏发电功率的精准预测和稳定控制,为电力系统的运行和规划提供了更加可靠的支持。同时,针对极端天气条件下温度敏感负荷波动剧烈

的问题,文献[10]提出了一种基于时序对抗生成网络的卷积神经网络预测方法。该方法能够充分利用历史数据和实时气象信息,对温度敏感负荷进行精准预测,为虚拟电厂的调度和决策提供科学依据。

上述研究从虚拟电厂的分布式能源资源预测、电能质量与可靠性提升、数据处理与分析技术引入以及光伏不确定性数据挖掘等多个方面入手,推动了虚拟电厂技术的快速发展和广泛应用。这些研究显著提升了虚拟电厂的电力利用效率、系统响应速度、能源管理水平和调度决策的科学性。然而,由于虚拟电厂用电负荷具有复杂性、多变性和不确定性,导致传统的负荷预测方法难以准确捕捉其动态特性,进而影响了虚拟电厂的电力调度精度、能源消纳效率和系统稳定性^[11]。

针对虚拟电厂运行负荷预测中存在的挑战,特别是考虑到负荷数据所固有的季节性和趋势性特征^[12],传统预测方法如基于梯度提升决策树(gradient boosting decision tree, XGBoost)、支持向量机(support vector machine, SVM)和反向传播神经网络(back propagation neural network, BPNN)均存在各自的局限性。其中,XGBoost 虽然在处理复杂数据集上表现出色,但在捕捉时间序列数据的季节性、趋势性和长期依赖关系方面存在不足;SVM 虽然能够处理非线性问题,但训练速度慢、对异常值敏感,且其非线性处理能力在面对复杂时间序列数据时显得有限;BPNN 作为多层前馈神经网络,虽具有强大的学习能力,但易陷入局部最优解,还面临梯度消失和爆炸的问题,导致其对时间序列特性的捕捉不够精确。为解决上述问题,下面提出了一种基于特征分解的虚拟电厂运行负荷预测方法。该方法首先采用基于局部加权散点平滑法(locally weighted scatterplot smoothing, LOESS)的季节趋势分解(seasonal-trend decomposition using LOESS, STL),以精确捕捉虚拟电厂负荷数据中的长期趋势、季节性波动等关键特征。随后,结合温度、节假日效应等外部影响因素,构建了 LSTM 负荷预测模型^[13]。通过选取虚拟电厂数据进行实验验证,对比预测结果与实际负荷数据,评估了模型的预测精度、鲁棒性和泛化能力。实验结果表明,该方法不仅能够准确预测虚拟电厂的未来负荷变化,还能有效应对各种外部因素的不确定性,为虚拟电厂的电力调度和资源优化配置提供了有力的决策支持。

1 虚拟电厂分布式能源出力特性分析

虚拟电厂是一种新型能源管理系统,整合了风力发电、光伏发电、小型发电机、燃料电池等多种发电设备及储能系统^[14]。其中:风力与光伏发电是核心,推动清洁能源利用^[15];其他发电设备作为补充,确保电力稳定并优化生产;储能系统则平衡电网供需,提高电能利用效率,减少对传统电网的依赖,从而增强电网的稳定性和可靠性^[16]。下面对虚拟电厂分布式能源出力特征进行分析。

1.1 风电机组

风力发电受到当地气候因素影响,自然风速的不稳定性决定了虚拟电厂的发电能力,风电机组的发电功率可表述为

$$P_w = \begin{cases} 0, & 0 < v < v_{in} \cup v > v_{out} \\ (v - v_{in})(v_r - v_{in})g_r, & v_{in} \leq v \leq v_r \\ g_r, & v_r \leq v \leq v_{out} \end{cases} \quad (1)$$

式中: P_w 为风电机组的发电功率; v 为自然风速; v_{in} 和 v_{out} 分别为切入和切出风速; v_r 为额定风速; g_r 为额定输出功率。

1.2 光伏发电

光伏发电的稳定性受到天气和光照影响,光伏发电机组的发电功率可表述为

$$P_{PV} = \eta_{PV} Q_{PV} \theta_{PV} \quad (2)$$

式中: P_{PV} 为光伏发电机组的发电功率; η_{PV} 为光伏板的光电转化系数; Q_{PV} 为光伏板的面积; θ_{PV} 为当地的光照强度。

1.3 化石燃料发电机组

由于虚拟电厂中的可再生分布式能源的发电能力受到环境因素制约,通常需要配备化石燃料发电机组(如柴油发电机)等设备来抑制可再生分布式能源发电的波动性,从而稳定虚拟电厂对外的电力输出,其表现形式为

$$P_o = \frac{T \times n}{\Phi} \quad (3)$$

式中: P_o 为化石燃料发电机组功率; T 为发动机的扭矩; n 为发动机的转速; Φ 为功率转换系数。

1.4 储能系统

由于环境因素的不可预测性,如天气变化等,可再生能源的发电能力呈现出显著的波动性。这种波动性不仅给电力系统的稳定运行带来了挑战,还因电力市场存在峰、平、谷期的分段式定价机制,进一步影

响了电力供应的经济性。储能系统能够在可再生能源发电过剩时储存多余的电能,并在发电不足或需求高峰时释放电能,从而有效平滑电力供需曲线,减少因可再生能源波动对电网造成的冲击。




图1 虚拟电厂的分布式能源架构

2 基于特征分解的虚拟电厂运行负荷预测方法

为了更全面地挖掘虚拟电厂运行负荷数据的特征并提升负荷预测的准确性,下面提出了基于特征分解的虚拟电厂运行负荷方法。首先,利用 STL 特征分解方法,对虚拟电厂的运行负荷数据进行深入解析。STL 方法能够有效地将时间序列数据分解为趋势特征、季节性特征和残差成分,从而区分并提取出负荷数据中的长期趋势性和周期特征,为后续的分析建模提供更为纯净的数据基础^[17]。随后,进一步考虑了影响虚拟电厂运行负荷的多种外部因素,并作为重要的输入变量纳入后续的预测模型中。在此基础上,构建了一个基于 LSTM 的负荷预测模型。LSTM 作为一种特殊的循环神经网络,擅长于捕捉时间序列数据中的长期依赖关系,非常适合处理像虚拟电厂运行负荷这样具有复杂动态特性的数据。最后,将 STL 分解得到的趋势性、季节性特征以及外部影响因素数据作为输入特征,通过多层 LSTM 单元进行特征学习和模式识别,最终输出未来一段时间内的负荷预测值。

2.1 STL 特征分解

STL 特征分解是一种用于时间序列分解的有效方法,通过调整参数来优化季节性和趋势性分量的提取,确保即使在数据中存在异常值时也能获得准确的分解结果。具体计算方法为

$$U_t = S_t + T_t + R_t, t \in [1, N] \quad (4)$$

式中: U_t 、 S_t 和 T_t 分别为 t 时刻虚拟电厂的负荷数据、季节特征和趋势特征; R_t 为残差特征; N 为时间序列数据的长度。

STL 通过执行内外循环实现对虚拟电厂负荷数据的分解, 具体分解方法为:

1) 去除趋势项。用虚拟电厂的运行负荷数据 U_t 减去第 $k-1$ 次内循环的趋势特征 $U_t - T_{t,k}$, 其中取 $T_{t,k}$ 的初始值取 0, 并进行迭代更新。

2) 对子序列进行平滑处理。基于 LOESS 对所有子序列进行回归, 选择适当的周期参数, 并向前后各延展一个周期, 利用平滑结果构建临时季节分量 $S_{t,k+1}^{\text{temp}}$ 。

3) 周期子序列的低通量过滤。根据步骤 2 计算的 $S_{t,k+1}^{\text{temp}}$ 进行滑动平均, 滑动平均的周期取值作为 LOESS 周期参数的值, 继续用 LOESS 对回归结果再次进行回归, 以提取周期子序列的低通量, 得到的结果记作 $L_{t,k+1}$ 。

4) 提取和去除季节特征。其中提取的季节特征为 $S_{t,k+1} = S_{t,k+1}^{\text{temp}} - L_{t,k+1}$ 。去除季节特征的操作则为 $U_t - S_{t,k+1}$ 。

5) 进行趋势平滑操作。对去除季节特征后的数据进行 LOESS 残差分析, 趋势特征记作 $T_{t,k+1}$ 。

最后, 当内迭代达到预定的精度要求时, 内循环终止。随后, 执行外循环, 利用提取的季节和趋势特征计算负荷数据的残差特征 R_t 。

$$R_{t,k+1} = U_t - S_{t,k+1} - T_{t,k+1} \quad (5)$$

在处理虚拟电厂运行负荷时, 将较大 R_t 视为异常值, 据此计算权重系数。并根据权重系数更新季节性和趋势特征, 以减小异常值对结果的影响。权重计算公式为

$$\rho_t = \begin{cases} [1 - (|R_t|/h)^2]^2, & 0 \leq |R_t|/h < 1 \\ 0, & |R_t|/h \geq 1 \end{cases} \quad (6)$$

式中: ρ_t 为 t 时刻的权重; $h = 6 \times m_{\text{edian}}(|R_t|)$, $m_{\text{edian}}(\cdot)$ 为求解时间序列数据的中位数。

2.2 LSTM 负荷预测模型

在 STL 特征分解的基础上提取了虚拟电厂运行负荷的趋势性和季节性特征, 下一步是建立负荷预测模型。较于传统前馈神经网络, 循环神经网络通过连接连续时间步长, 能捕获时间依赖性并提取相关特征。但其在处理长序列数据时易遭遇梯度消失或爆炸问题, 影响长时间依赖关系的获取^[18]。为解决此问题, 采用 LSTM 构建虚拟电厂运行负荷预测模型。其中, LSTM 网络由多个 LSTM 单元依次连

接而成, 一个 LSTM 单元主要由 4 个部分组成: 遗忘门、输入门、存储单元状态和输出门, 其基本结构如图 2 所示。LSTM 模块中各门函数的计算公式可表示为:

$$f_t = \sigma(\omega_f \cdot [h_{t-1}, x_t] + b_f) \quad (7)$$

$$i_t = \sigma(\omega_i \cdot [h_{t-1}, x_t] + b_i) \quad (8)$$

$$\tilde{C}_t = \tanh(\omega_c \cdot [h_{t-1}, x_t] + b_c) \quad (9)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (10)$$

$$o_t = \sigma(\omega_o \cdot [h_{t-1}, x_t] + b_o) \quad (11)$$

$$h_t = o_t \cdot \tanh C_t \quad (12)$$

$$\sigma = 1/(1 + e^{-x}) \quad (13)$$

式中: f_t 为遗忘门; i_t 为输入门; $\tilde{C}_t$ 为候选记忆细胞; C_{t-1} 和 C_t 分别为 LSTM 单元在前一个细胞单元和当前细胞单元的状态; o_t 为输出门; h_{t-1} 和 h_t 分别为前一个细胞单元和当前细胞单元的隐藏状态; x_t 为当前时间的输入向量; σ 为 sigmoid 函数; $\tanh$ 为双曲正切函数; ω 和 b 分别为对应各部分的权重参数和偏置项。




图 2 LSTM 预测模型的基本结构

3 实验验证

所采用的实验数据来源于一个集成了光伏发电、储能系统和风力发电的虚拟电厂, 时间跨度从 2021 年至 2024 年。虚拟电厂具备灵活的电力调度能力, 不仅能够将多余电力及时输送到主电网中, 以满足电力峰值的需求, 还能在电价低谷期有效利用储能系统存储主电网的多余电力, 从而实现电力的平衡和优化配置。其中, 电力峰期和谷期因供需变化而带来的负荷波动, 均与节假日的电力消费模式以及温度等环境因素具有高度关联性。因此, 在深入分析虚拟电厂负荷特性时, 充分考虑了节假日和温度这两个对虚拟电厂运行负荷产生显著且复杂影响的外部因素, 以期准确预测和评估虚拟电厂的运行状态和性能。

在上述数据的基础上,构建 LSTM 负荷预测模型,并将预测结果和 XGBoost、SVM、BPNN、门控循环单元(gated recurrent unit,GRU)等多种预测方法的结果对比,以验证所提方法的准确性。

3.1 案例数据分析

3.1.1 虚拟电厂负荷数据

虚拟电厂用电负荷数据如图 3 所示,负荷呈现出鲜明的日周期性变化特征。具体而言,负荷峰值显著地集中于白天时段,尤其是工作日的上午至傍晚,这与人们日常的生产生活活动紧密相连,如工业生产、商业运营及居民生活用电等均在此时间段内达到高峰。相对地,负荷低谷则自然而然地出现在夜间,此时大部分生产活动暂停,居民用电也大幅下降。负荷在一天之内的波动幅度不仅大,而且具有一定的规律性,这深刻反映了电力需求的日变化特性,即“昼高夜低”的基本模式。面对如此显著的负荷波动,虚拟电厂必须具备高度的灵活性和强大的调节能力,才能有效平衡供需,确保电力系统的稳定运行。因此,精准预测虚拟电厂的用电负荷可以为电力调度提供科学依据提前布局,如合理安排发电资源、优化储能配置,以及必要时采取需求响应措施,从而应对负荷波动带来的挑战。




图 3 虚拟电厂负荷数据

3.1.2 外部因素数据分析

在实验数据中,电动汽车充电站作为虚拟电厂用电负荷的主要来源,温度和节假日是影响电动汽车充电的重要因素。外部因素中的温度变化如图 4 所示。温度是影响电动汽车充电需求的重要因素之一。在极端高温或低温天气下,为了维持车内舒适环境,电动汽车的空调系统会消耗更多电能,因此会增加车辆充电的需求。此外,温度还会影响电池的性能和效率,间接影响充电时间和充电量。因此,温度变化对虚拟电厂负荷预测的准确性具有重要影响,必须纳入数据分析模型中进行细致考虑。




图 4 外部因素的温度变化

节假日期间虚拟电厂的用电负荷如图 5 所示。由于节假日期间人们的出行模式与工作日大相径庭,这直接导致了电动汽车充电需求的波动。例如,长假期间,随着家庭自驾游的增多,电动汽车的充电需求会激增;相反,在部分短假期或特定节日习俗下,充电需求会减少。因此,节假日对电动汽车充电负荷的预测和管理提出了更高要求,需要在数据分析中予以充分考虑。




图 5 节假日期间虚拟电厂用电负荷

3.2 STL 特征分解

基于 STL 方法提取的趋势特征和季节特征如图 6 所示。首先,虚拟电厂负荷的趋势特征呈现出逐步增长的趋势,这与电动汽车的数量不断增加相




图 6 STL 分解特征

符合。其次,虚拟电厂负荷的季节特征展示了负荷在一定时间段内呈现出周期性波动,如在部分月份的负荷要高于其他时间。最后,负荷数据的残差特征代表着负荷数据中无法以趋势性和季节性解释的部分信息,包括随机波动和异常值,这与虚拟电厂负荷存在一定的不确定性相关。

3.3 基于 STL 特征分解的 LSTM 负荷预测

在 STL 提取的趋势特征、季节特征和残差特征的基础上,结合虚拟电厂负荷影响的外部因素,构建了基于 STL-LSTM 的虚拟电厂负荷预测模型。其中,在数据集划分中将收集到的数据集按照 70%、20%、10% 的比例划分为训练集、验证集和测试集。具体而言,70% 的数据用于模型的训练和学习;20% 的数据作为验证集,用于在训练过程中调整模型参数和选择最佳模型;剩余的 10% 数据作为测试集,用于最终评估模型的性能。LSTM 训练过程的损失曲线如图 7 所示,模型在 400 轮左右实现损失收敛,模型的预测结果达到最优。




图 7 STL-LSTM 负荷预测模型

3.4 预测结果对比分析

下面采用平均绝对误差 (mean absolute error, MAE)、均方误差 (mean squared error, MSE) 以及决定系数 (R^2) 3 项指标来评估能耗预测模型的效能。其中,MAE 因其对异常值的低敏感性,在数据含有噪声或异常值时能提供稳定的模型评估结果,有助于把握模型的整体表现。相比之下,MSE 对异常值更为敏感,较低 MSE 值意味着模型预测性能更佳。 R^2 用于量化模型的拟合程度,其取值范围在 0~1 之间, R^2 值越趋近于 1,表明模型与数据的拟合度越高。综上所述,结合 MAE、MSE 与 R^2 3 项指标,可以在不同场景下为预测模型的性能提供一个全面

的评估视角,既涵盖了预测误差的分布情况,也反映了模型的拟合优劣。这些指标的计算公式为:

$$M_{AE} = \frac{1}{n} \sum_{i=1}^n |y_i - y_i^*| \quad (14)$$

$$M_{SE} = \frac{1}{n} \sum_{i=1}^n (y_i - y_i^*)^2 \quad (15)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - y_i^*)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (16)$$

式中: n 为虚拟电厂负荷数据的长度; y_i^* 和 y_i 分别为第 i 个样本的实际值和预测值; $\bar{y}_i$ 为样本的平均值。

不同算法的预测结果评价指标如图 8 所示。其中,所提 STL-LSTM 的 R^2 为 0.98 时预测效果最好。STL-LSTM 模型结合了 STL 分解和 LSTM 模型的各自优势:STL 分解能够将原始时间序列数据分解为趋势、周期和随机序列,从而简化数据并提升预测精度及模型解释性;LSTM 模型则擅长处理时间序列中的长期依赖关系,具有门结构控制、细胞状态保存以及适应性强等特性。STL 与 LSTM 的结合通过数据预处理、分别建模和预测以及结果组合等步骤,充分利用了分解后的数据信息,实现了对时间序列数据的精确预测。




图 8 不同算法的预测指标

不同算法的预测结果如图 9 所示。其中,XGBoost 是一种给予梯度提升的预测算法,但其无法很好地捕捉时间序列数据中的长期依赖关系;SVM 在处理非线性关系时可能需要额外的技巧或特征工程,且其非线性处理能力在面对复杂时间序列数据时显得有限;BPNN 可能受到梯度消失或爆炸问题的影响;GRU 虽然也是一种循环神经网络,但其门控机制可能不如 LSTM 复杂,因此在处理长期依赖关系时可能表现不如 LSTM。STL-LSTM 模型能够充分利用 STL 在时间序列分解上的优势,以

及 LSTM 在处理长期依赖关系上的能力,从而实现虚拟电厂运行负荷的更精确预测。




图 9 不同算法预测结果对比

4 结 论

上面以虚拟电厂的用电负荷为预测目标构建了基于特征分解的虚拟电厂运行负荷预测方法。该方法首先使用 STL 特征分解方法,将虚拟电厂的用电负荷分解为趋势特征、季节特征和残差特征;同时,考虑到电动汽车充电桩作为该虚拟电厂负荷的主要来源,节假日和温度作为影响其充电功率的主要外部因素,将其与 STL 方法提取的分解特征相结合构建预测指标体系;然后,基于构建的预测指标体系,建立基于 LSTM 的虚拟电厂用电负荷预测模型;最后,以 MAE、MSE 和 R^2 为预测结果评价指标并与多种不同算法进行对比分析,证明了所提出的基于特征分解的虚拟电厂运行负荷预测方法的准确性和优越性。

参考文献

[1] 曾鸣,马嘉欣,许彦斌,等. “双碳”目标下虚拟电厂参与调峰产品交易的机制与路径探索[J]. 价格理论与实践,2021(10):9-14.

[2] 唐岚,束洪春,于继来. 风能资源估算中的不确定性分析[J]. 太阳能学报,2011,32(10):1560-1565.

[3] 许泽凯,和敬涵,刘墨,等. 基于耦合约束解耦的虚拟电厂动态可行域求解方法[J]. 中国电机工程学报,2024,44(9):3440-3452.

[4] 赵丰明,樊艳芳. 分时电价影响下的多能源虚拟电厂双层优化调度[J]. 电力系统保护与控制,2019,47(20):33-40.

[5] 戴睿鹏,窦晓波,喻洁,等. 含光储充的配网虚拟电厂二次调频随机模型预测控制策略[J]. 电网技术,2024,48(8):3228-3237.

[6] 杨成鹏,侯萌,张曦,等. 面向分布式能源能量交互画像的虚拟电厂信息流量预测方法[J]. 电力信息与通

信技术,2024,22(6):18-27.

[7] 杨玉锐,姚强,钱金跃,等. 基于高弹性电网的虚拟电厂短期负荷预测[J]. 电力大数据,2022,25(6):9-15.

[8] 洪媛,黄亮,谢长君,等. 基于边缘计算的虚拟电厂架构及光伏出力预测算法研究[J]. 湖北电力,2020,44(1):26-34.

[9] 高琳,刘甲林,李静. 基于 VAE-CGAN 的虚拟电厂光伏不确定性数据挖掘[J]. 电子产品世界,2024,31(4):22-24.

[10] 周颖,白雪峰,王阳,等. 面向虚拟电厂运营的温度敏感负荷分析与演变趋势研判[J]. 中国电力,2024,57(1):9-17.

[11] 原启涛,李志勇,燕续峰,等. 分布式能源资源的通用数字孪生体构建与模拟方法[J]. 可再生能源,2022,40(6):822-829.

[12] 王晓玲,王成,王佳俊,等. 大坝渗压混合预测的 STL 分解-集成学习模型[J]. 水力发电学报,2024,43(9):106-123.

[13] 乔长建,刘震,邵建豪. 基于 LSTM 的水文站流量短期预测建模差异性研究[J]. 人民黄河,2024,46(6):119-125.

[14] 刘国新,吴杰康,蔡志宏,等. 基于条件风险价值风险控制的多电源虚拟电厂机组动态聚合优化模型[J]. 四川电力技术,2022,45(3):8-15.

[15] 罗翼婷,杨洪明,牛犇,等. 考虑多风能预测场景的虚拟电厂日内滚动柔性优化调度方法[J]. 电力系统保护与控制,2020,48(2):51-59.

[16] 张晋磊,付春立,唐志均,等. 考虑多源互补特性的新能源打捆销售交易策略[J]. 四川电力技术,2024,47(3):31-38.

[17] 殷建华,戴冠正,丁宁,等. 基于 STL-Informer-BiLSTM-XGB 模型的供热负荷预测[J]. 科学技术与工程,2024,24(21):8942-8949.

[18] 刘昱辰,刘佳,刘录三,等. 基于 LSTM 实时校正的 WRF/WRF-Hydro 耦合径流预报[J]. 水利学报,2023,54(11):1334-1346.

作者简介:

潘 翀(1980),男,博士,高级工程师,研究方向为电网规划;

郝文斌(1976),男,博士,高级工程师,研究方向为电力系统规划设计;

谢 波(1989),男,博士,高级工程师,研究方向为电力系统规划;

孟志高(1990),男,博士,高级工程师,研究方向为电力系统规划;

何凌云(1992),女,硕士,工程师,研究方向为电力系统规划;

卫佳奇(1992),女,工程师,研究方向为电力系统分析。

(收稿日期:2024-10-26)