

基于PCC-ML深度学习的微电网多目标协调优化运行

李建杰,盖鹏宇,王历华,张健,孙洪波,辛春青

(国网山东省电力公司 滨州供电公司,山东 滨州 256610)

摘要:为提高微电网可再生能源优化配置,降低微电网源荷不确定性,提出基于Pearson相关系数元学习(PCC-ML)源荷预测的微电网多目标协调调度优化方法。首先,运用Pearson相关性分析(PCC)分析原始多维输入变量组成的时间序列,通过元学习(ML)对微电网源荷数据进行特征提取、候选模型准备、标记、离线训练和在线预测结果评估5个过程管理;然后,基于预测结果建立微电网两阶段滚动调度优化模型,阶段一为日前预调度阶段,以实现微电网区域全局运行经济性最优为优化目标;阶段二为实时运行调控阶段,考虑微电网新能源实时出力不确定性,对预测偏差实时调控,实现微电网各设备运行成本最优。接着,利用列约束生成算法(C&CG)分解为主、子问题进行交互迭代求解两阶段优化模型。最后,算例分析表明所提方法能满足可见和不可见预测任务的性能需求,提高微电网经济收益。

关键词:微电网;源荷预测;元学习;调度优化;列约束生成算法

中图分类号:TM73 **文献标识码:**A **DOI:**10.19457/j.1001-2095.dqed24113

Multi-objective Coordinated and Optimized Operation of Microgrid Based on PCC-ML Deep Learning

LI Jianjie, GAI Pengyu, WANG Lihua, ZHANG Jian, SUN Hongbo, XIN Chunqing

(Binzhou Power Supply Company, State Grid Shandong Electric Power Company,
Binzhou 256610, Shandong, China)

Abstract: In order to improve the optimal allocation of renewable energy in microgrid and reduce the uncertainty of source load in microgrid, a multi-objective coordinated scheduling optimization method for microgrid based on Pearson correlation coefficient meta-learning (PCC-ML) source load prediction was proposed. Firstly, Pearson correlation analysis was used to analyze the time series composed of original multidimensional input variables, and meta-learning (ML) was used to manage the five processes of feature extraction, candidate model preparation, labeling, off-line training and online prediction result evaluation for microgrid source load data. Then, based on the prediction results, a two-stage rolling scheduling optimization model of microgrid was established. The first stage is day-ahead pre-scheduling stage, and the optimization goal is to achieve the global economic optimization of microgrid region. The second stage is the real-time operation and regulation stage. Considering the uncertainties of the real-time output of new energy sources in microgrid, the prediction deviation is regulated in real time to realize the optimal operation cost of each equipment in microgrid. Then, the column constraint generation algorithm (C&CG) was used to decompose the main and sub-problems into interactive iterations to solve the two-stage optimization model. Finally, an example shows that the proposed method can meet the performance requirements of visible and invisible forecasting tasks and improve the economic benefits of microgrid.

Key words: micro-grid; source load prediction; meta-learning(ML); scheduling optimization; column constraint generation algorithm(C&CG)

国家双碳目标下,高效、清洁、低碳的可再生能源发电技术成为电力能源发展的主流,但其不确定性急剧增加了微电网系统源荷预测需求^[1]。

考虑微电网系统运行特性、天气状况等相关影响因素,基于历史数据,实现源荷精确预测,制定优化调度计划,有助于提高发电效率和能源利用

作者简介:李建杰(1978—),男,硕士,高级工程师,主要研究方向为深度学习在配电网中的应用,Email:1025917795@qq.com

率,降低运营成本,保障微电网安全稳定运行。不同的源荷预测任务,分布式电源和需求响应计划的时间和集成技术要求不尽相同,如何在满足高维度、非线性源荷预测精度的同时,实现微电网系统的高效优化调度是电力领域亟待解决的难题。

近年来,国内外诸多学者运用机器学习算法进行了源荷预测,搭建了深度学习预测模型^[2-4]、概率预测模型^[5-6]、人工神经网络预测模型^[7-8]和混合预测模型^[9-10],取得了丰硕成果。随着深度学习^[11]、强化学习^[12]等前沿机器学习模型在电力领域的出色应用,元学习(meta-learning, ML)也被引入到电力系统源荷预测应用中。文献[13]设计了基于Stacking集成学习算法的短期负荷预测模型,解决了同一元学习器下不同预测模型预测结果差异性。文献[14]为提高负荷预测精度,纠正基预测器系统偏差,建立了一种基于元学习的时变非线性预测算法进行电力负荷超短期预测。文献[15]考虑光伏发电和负荷时变特性,为提升动态消纳能力,提出了一种基于频域分解的短期负荷预测方法。上述元学习负荷预测模型获得了丰硕的研究成果,仍存在下列问题:1)引入的ML结构不能将负荷预测更好地转化为元学习问题;2)选择的经典ML算法未建立预测任务特征到最优预测结果的有效映射,需

要制定加权机制对其进行组合评估,推荐最终结果;3)负荷预测任务没有设置严格标准,基于ML方法的性能无法被适当量化,降低了预测准确性。

鉴于上述问题,以及微电网ML源荷预测的鲜有研究,提出基于皮尔逊相关系数(Pearson correlation coefficient, PCC)元学习(PCC-ML)的微电网源荷协调优化调度模型。首先构建特征提取、候选模型准备、标记、离线训练及在线预测结果评估等过程的源荷预测框架。将用户负载预测需求和数据特征作为输入特征。其次利用多个ML指标对可用源荷预测模型的预测精度排序,通过评分投票机制加权各ML,推荐最终预测结果。然后针对微电网中新能源出力不确定性,建立微电网两阶段滚动调度优化模型,最后利用列约束生成(column constraint generation, C&CG)算法将文章构建的两阶段优化模型分解为主、子问题进行交互迭代求解。最后通过算例分析验证了本文所提方法的有效性和经济性。

1 PCC-ML融合算法

1.1 元学习模型

元学习具有较强的自我学习能力和泛化能力,由基础学习层和元学习层完成学习过程,学习机理如图1所示。




图1 元学习系统学习机理示意图

Fig.1 Schematic diagram of learning mechanism of meta-learning system

将第*i*个源荷预测任务的训练集表示为

$$(X_i)_{\text{train}} = \begin{Bmatrix} (x_1)_1 & (x_1)_2 & \cdots & (x_1)_M \\ (x_2)_1 & (x_2)_2 & \cdots & (x_2)_M \\ \vdots & \vdots & \vdots & \vdots \\ (x_N)_1 & (x_N)_2 & (x_N)_3 & (x_N)_M \end{Bmatrix} \quad (1)$$

式中: $(X_i)_{\text{train}}$ 为第*i*个源荷训练任务; $(x_N)_M$ 为第*N*个源荷预测任务第*M*个训练数据。

若将 $(y_{i,h})_{\text{train}}$ 表示第*i*个源荷预测任务由第*h*个源荷预测模型预测的源荷,基础学习层问题如下:

$$\begin{cases} (y_{i,h})_{\text{train}} = f_{\theta}^h[(X_i)_{\text{train}}] \\ \theta = \operatorname{argmin} \Psi^{\text{base}}[(y_{i,h})_{\text{train}}, (y_i)_{\text{train}}] \end{cases} \quad (2)$$

式中: $(y_i)_{\text{train}}$ 为第 i 个源荷预测任务; f_{θ}^h 为参数 θ 的 h 负荷预测模型函数; Ψ^{base} 为预测源荷与实际源荷间的距离损失函数; θ 为源荷预测模型最优参数。

确定最优参数后,运用均方根误差(root mean squared error, RMSE)衡量预测精度,则有:

$$\begin{cases} (y_{i,h})_{\text{test}} = f_{\theta}^h[(X_i)_{\text{test}}] \\ Z(h,i) = \|(y_{i,h})_{\text{test}}, (y_i)_{\text{test}}\|_2 \end{cases} \quad (3)$$

式中:下标“test”为相应的测试任务变量; $Z(h,i)$ 为第 i 次负荷预测任务中负荷预测模型 h 的均方根误差。

选择精度最高的源荷预测模型 h_i 作为第 i 个任务的推荐源荷预测模型,汇总形成新样本集,将其索引到元学习层。

元学习目标是寻找源荷预测任务的最优预测结果,数学表达式为

$$\begin{cases} \phi_{i,h^*} = g_{\theta^*}^h(F_{\text{train}}) \\ w^* = \operatorname{argmin} \varphi^{\text{meta}}[(\phi_{h^*})_{\text{train}}, \phi_{\text{train}}] \end{cases} \quad (4)$$

式中: ϕ_{i,h^*} 为最佳负荷预测模型; ϕ_{train} 为训练后的负荷预测模型; $g_{\theta^*}^h$ 为参数 θ^* 的元学习模型 h^* 的精度参数; F_{train} 为输入特征训练元学习,表示元学习器参数的最优集合; φ^{meta} 为损失函数,用来度量元学习推荐的负荷预测模型 $(\phi_{h^*})_{\text{train}}$ 与 ϕ_{train} 间的距离。

确定参数 h^* 后进行元学习性能测试,计算精度公式如下:

$$\hat{\Phi}_{i_M}^{\text{test}} = g_{w^*}^{i_M}(F^{\text{test}}) \quad (5)$$

式中: F^{test} 为元学习测试结果; $\hat{\Phi}_{i_M}^{\text{test}}$ 为 F^{test} 元学习测试后推荐的预测结果; $g_{w^*}^{i_M}$ 为元学习 i_M 的精度参数。

由于学习器与源荷预测任务的多样性,需要对不同元学习器的源荷预测模型结果评分投票加权,最终推荐结果,计算公式为

$$\eta = \frac{1}{I - K_M} \sum_{i=K_M+1}^I H_{[\phi = \phi_{\text{test}}(i)]} \quad (6)$$

式中: η 为元学习器的准确性; I 为源荷预测任务集; K_M 为元学习器训练的负荷预测任务集; H 为负荷预测模型集; $\phi_{\text{test}}(i)$ 为学习任务的测试模型。

1.2 PCC-ML 源荷预测模型

基于 PCC-ML 的源荷预测模型结构图如图 2 所示。




图2 PCC-ML模型结构图

Fig.2 Structure diagram of PCC-ML model

图2中,首先对输入数据样本的影响因素作 Pearson 相关系数(Pearson correlation coefficient, PCC)分析,相关系数 $P_{A,B}$ 分析变量 A, B 相关程度,并以相关系数绝对值表示,公式如下式:

$$P_{(A,B)} = \frac{E(AB) - E(A)E(B)}{\sqrt{E(A^2) - [E(A)]^2} \sqrt{E(B^2) - [E(B)]^2}} \quad (7)$$

式中: P 为相关系数; E 为数学期望。

$P_{A,B} = 0$, A 与 B 无关; $P_{A,B} \in (-1,0)$, A 与 B 负相关; $P_{A,B} \in (0,1)$, A 与 B 正相关, $P_{A,B}$ 绝对值越大,相关程度越高。

判断是否会对负荷产生影响;然后运用 ML 进行源荷预测,在 ML 模型的基础学习层与元学习层后添加全连接层(Dense),时刻监督汇总不同时段数据对当前影响,并输出结果,从而得到预测日源荷用电量。

2 微电网两阶段协调调度优化模型

采用 PCC-ML 方法进行源荷预测,进一步考虑微电网奖惩费用和运维成本,建立微电网两阶段滚动调度优化模型,以最优运行成本为目标实现微电网系统源荷协调调度。

阶段一为日前预调度阶段以实现微电网区域全局运行经济性最优为优化目标,目标函数如下:

$$\min M_{\text{total}} = \sum_{t=1}^T [M_F(t) + M_E(t) + M_I(t) + M_{\text{RP}}(t)] \quad (8)$$

其中

$$M_F(t) = \frac{P_F(t)}{\lambda_F} \frac{\Delta t}{l_{NGP}} d_{NGP}$$

$$M_E(t) = \sum_{j=1}^z P_j(t) c_j + |P_{ESE}(t)| c_{ESE}$$

$$M_I(t) = H_1 [\min(0, k_1)]^2 + H_2 k_2^2 - (W_e - W_{e0}) P_{ri}(t)$$

$$M_{RP}(t) = B_r(t) \max\{P_{RP}(t), 0\} + B_s(t) \max\{-P_{RP}(t), 0\}$$

式中: M_{total} 为总成本; T 为总时间段数, $T = 24$; $M_F(t)$ 为 t 时刻燃料成本; $M_E(t)$ 为 t 时刻发电设备运维成本; z 为发电设备总数; $P_{ri}(t)$ 为弃光功率; $M_{RP}(t)$ 为 t 时刻配电网和微电网交互成本; $M_I(t)$ 为 t 时刻奖惩成本; $P_F(t)$ 为 t 时段燃气轮机出力效率; Δt 为单位调度时间; λ_F 为燃气轮机发电率; l_{NGP} 为天然气低热值; d_{NGP} 为天然气价格; $P_j(t)$ 为发电机组发电功率; c_j 为发电机组单位维护成本; c_{ESE} 为储能设备单位维护成本; $P_{ESE}(t)$ 为储能设备充放电功率; k_1, k_2 为不等式约束和等式约束条件; W_e, W_{e0} 为当前能源利用率和标准能源利用率; H_1, H_2 为不满足条件时的惩罚因子; $B_r(t)$ 为购电价; $B_s(t)$ 为售电价; $P_{RP}(t)$ 为微电网和主网购售电功率, 正值为购电, 负值为售电。

文中对于微电网运行约束主要包括电力平衡约束、联络线传输约束、分布式电源出力上、下限以及储能出力上、下限, 其约束条件表达式为

$$\begin{cases} P_{\text{load}}(t) - P_F(t) - P_{\text{dg}}(t) - P_{RP}(t) - P_{ES}(t) = 0 \\ \sum_{t=1}^T P'_{\text{load}}(t) = \sum_{t=1}^T P_{\text{load}}(t) \\ \sum_{t=1}^T P'_{\text{load}}(t) D'_{EP}(t) \leq \sum_{t=1}^T P_{\text{load}}(t) D_{EP}(t) \\ P_i^{\min} \leq P_i(t) \leq P_i^{\max} \\ -\beta_i^{\text{down}} \Delta t \leq P_i(t) - P_i(t-1) \leq \beta_i^{\text{up}} \Delta t \\ P_{RP}^{\min}(t) \leq P_{RP}(t) \leq P_{RP}^{\max}(t) \\ P_{ESO}^{\min} \leq P_{ESO}(t) \leq P_{ESO}^{\max} \\ C^{\min} \leq C(t) \leq C^{\max} \end{cases} \quad (9)$$

式中: $P_{\text{load}}(t)$ 为用户用电负荷; $P_{\text{dg}}(t)$ 为风电出力; $P_{ES}(t)$ 为储能设备充放电功率; P'_{load} 为用户需求响应的源荷量; D'_{EP} 为用户需求响应的电价; $D_{EP}(t)$ 为用户电价; $P_i^{\min}, P_i^{\max}$ 分别为发电机组最小、最大发电功率; $\beta_i^{\text{down}}, \beta_i^{\text{up}}$ 为分布式发电机组爬坡率下限、上限值; $P_i(t)$ 为发电机组实时发电功率; $P_{RP}^{\min}, P_{RP}^{\max}$ 分别为联络线传输功率最小、最大值; $P_{ESO}^{\min}, P_{ESO}^{\max}$ 分别为储能出力的最小、最大值; $C^{\min}, C^{\max}$ 分别为储能荷电最小、最大值。

阶段二为实时运行调控阶段, 主要考虑微电网内新能源实时出力的不确定性因素, 对预测偏差进行滚动优化控制, 实现微电网内各设备运行最

优, 提高风电与用电负荷的匹配程度, 目标函数为

$$\min G = \Delta M^{G,\text{up}} + \Delta M^{G,\text{down}} + \Delta M^{\text{ES}} + \Delta M^{\text{M}} \quad (10)$$

其中

$$\Delta M^{G,\text{up}} = \sum_{t=1}^T \sum_{j=1}^M \lambda_{jd}^{\text{up}} P_{jd}^{\text{up}}$$

$$\Delta M^{G,\text{down}} = \sum_{t=1}^T \sum_{j=1}^M \lambda_{jd}^{\text{down}} P_{jd}^{\text{down}}$$

$$\Delta M^{\text{ES}} = \sum_{t=1}^T (C^{\text{ch}} \Delta P_t^{\text{ch}} - C^{\text{dis}} \Delta P_t^{\text{dis}})$$

$$\Delta M^{\text{M}} = \sum_{t=1}^T \lambda^{\text{M}} (\Delta P_t^{\text{ja}} - \Delta P_t^{\text{jr}})$$

式中: G 为阶段二实时运行调控成本函数; $\Delta M^{G,\text{up}}, \Delta M^{G,\text{down}}$ 分别为实时调控上调、下调功率值; ΔM^{ES} 为储能实时调控功率值; ΔM^{M} 为微电网与配电网交互电量值; $P_{jd}^{\text{up}}, \lambda_{jd}^{\text{up}}$ 和 $P_{jd}^{\text{down}}, \lambda_{jd}^{\text{down}}$ 分别为分布式发电设备的上调功率、上调单位功率成本和下调功率、下调单位功率成本; $\Delta P_t^{\text{ch}}, \Delta P_t^{\text{dis}}$ 分别为储能设备充电和放电调控功率; $\Delta P_t^{\text{ja}}, \Delta P_t^{\text{jr}}$ 分别为微电网从配电网购买电量和出售电量变化量; $C^{\text{ch}}, C^{\text{dis}}$ 分别为储能系统充、放电成本; λ^{M} 为电价调整。

3 模型求解

3.1 基于评分投票机制的源荷预测模型求解

不同模型结构组合能更有效地实现既定源荷预测任务, 因此, 文本考虑季节性差分自回归滑动平均算法 (seasonal autoregressive integrated moving average, SARIMA)、长期短期记忆神经网络 (long short-term memory, LSTM)、支持向量机回归算法 (support vector regression algorithm, SVRA) 和相似日 (similarity day, SD) 预测算法 4 种常用预测模型, 负荷预测模型结构如表 1 所示, 其中, Fickieness 为浮躁度量时间序列与均值的比值; H-ACF (highest autocorrelation function) 为最高自相关函数; H-PACF (highest partial autocorrelation function) 为最高偏自相关函数。

表 1 负荷预测模型结构

Tab.1 Structure of load prediction model

序号	候选源荷预测模型	序号	候选源荷预测模型
1	数据长度	9	最大值
2	天气特征数量	10	标准差
3	数据粒度	11	峰度
4	预测范围	12	偏度
5	客户数量	13	Fickieness
6	复合类型	14	H-ACF
7	平均值	15	H-PACF
8	最小值	16	周期性

运用式(3)、式(4)迭代 L_i 次(直到 $\Omega_i(L_i)$ 和 $\Omega_i(L_i-10)$ 的Pearson相关系数 P_{cc} 大于0.95时停止),以分布估计图 Ω_i 形式得出最优源荷预测结果,迭代流程如图3所示。为更精确进行源荷预测,实现不可见源荷预测最优结果,考虑16个特征描述源荷预测任务(7~16是由历史源荷数据总结得出),利用Metalearner将元特征映射到模型,使其转为一个分类问题。选择随机森林(random forests, RF)、K-最近邻(K-nearest neighbor, KNN)、朴素贝叶斯(naive bayesian model, NBM)和线性判断(linear discriminant, LD)4种经典分类方法作为元学习的分类器。为了整合各元学习器的预测结果,构建了基于集成学习算法的评分投票机制。




图3 候选源荷预测模型选择标记流程图

Fig.3 Marking selection flow chart of candidate source-load prediction model

根据源荷预测测试结果,建立分类器分数 D_h 与预测准确性 S_h 关系,将分数转化为准确率 η_h ,公式如下:

$$\eta_h = D_h \cdot (S_h) \quad (11)$$

运用平均绝对百分比误差 y_{MAPE} 和均方根误差 y_{RMSE} 评估源荷预测结果,公式如下:

$$\begin{cases} y_{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{x_{act}(t) - x_{pred}(t)}{x_{act}(t)} \right| \times 100\% \\ y_{RMSE} = \sqrt{\frac{\sum_{t=1}^n [x_{act}(t) - x_{pred}(t)]^2}{n}} \end{cases} \quad (12)$$

式中: $x_{act}(t)$ 为 t 时刻负荷的实际值; $x_{pred}(t)$ 为 t 时刻负荷的预测值。

y_{MAPE} 和 y_{RMSE} 值越小表示误差越小,结果越准确。

3.2 两阶段协调调度优化模型求解

考虑微电网系统源荷不确定性集合,运用C&CG对两阶段协调优化模型进行求解,目标函数为

$$U = \min_A G + \max_{p_h \in \Omega} \left\{ \sum_{h=1}^H p_h \min_x \{F\} \right\} \quad (13)$$

式中: x 为日前最优经济调度方案; A 为应对 x 方案的最优经济实时调控方案。

其紧凑矩阵形式为

$$U = \min_A (c^T z + \max_{u \in \Omega} \min_{x \in \Theta(A, u)} d^T x) \quad (14)$$

其中

$$\Theta(A, \mu) = \begin{cases} KA \leq b \\ E(x) \leq \mu \\ FA + Gx = K\mu \end{cases}$$

式中: $c^T z$ 为日前预调度成本函数; $d^T x$ 为实时调控成本函数; μ 为不确定性量。

将两阶段协调优化模型解耦为主问题(main problem, MP)和子问题(subproblems, SP)迭代 n 次求解,表达式为

$$\begin{cases} \text{MP: } \min c^T z + \mu \\ \text{s.t. } \mu \geq \sum_{i=1}^I p_i^n \min \{d^T x^n\} \\ H_1(z) \leq 0 \\ G_1(z) = 0 \end{cases} \quad (15)$$

$$\begin{cases} \text{SP: } \max \sum_{i=1}^I p_i (d^T x^n) \\ \text{s.t. } H_2(zn, x) \leq 0 \\ G_2(zn, x) \leq 0 \\ p_i \in \Omega \end{cases} \quad (16)$$

列约束生成(C&CG)算法对两阶段协调优化模型进行求解流程如图4所示。

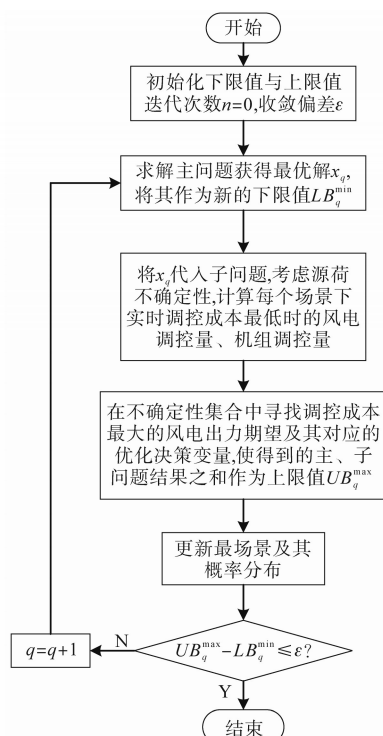


图4 C&CG算法的两阶段优化调度模型求解流程图

Fig.4 Solving flow chart of two-stage optimization scheduling model of C&CG algorithm

4 算例分析

4.1 实验环境配置与数据准备

本文搭建的负荷预测实验环境采用 Intel i7-10700 处理器, RTX2060 显卡。算法主要采用 Python3.8 作为编程语言, 软件架构主要是基于 Tensorflow 与 Pytorch 深度学习框架进行开发。并选取某市某用户 2019 年 10 月—2019 年 12 月 3 个月的实际数据作数据集, 数据集主要包括电力负荷数据、天气数据、温度数据等信息, 微电网集群参数具体设置如下所示: 配电网接入节点 18, 光伏容量 600 kWp, 储能额定容量 500 kW·h, 充/放电功率上限 400 kW, 充/放电效率 0.95, SOC 下限 0.15, SOC 上限 0.95, 初始 SOC = 0.15, 充/放电成本 0.36 元/(kW·h)。

4.2 源荷预测结果分析

图 5 为元学习深度学习对 2019 年 12 月份第二周周一 24 时的负荷预测结果, 由图可以看出文中所提预测方法进行光伏和负荷预测误差较小。

为进一步证明本文所提方法预测的准确性, 选取 SARIMA, LSTM, SVR, SD 与本文所提 PCC-ML 方法的用户负荷预测结果对比, 不同负荷预测方法具体误差参数与计算时间对比结果, 如表




图5 基于PCC-ML 24时光伏和负荷功率预测

Fig.5 PV and load power prediction based on PCC-ML 24 h 2 所示。由表 2 可以看出, PCC-ML 预测模型对光伏和负荷功率预测效果最优, LSTM 预测方法次之, SARIMA 方法预测效果最差。

表2 预测方法误差及计算时间对比

Tab.2 Comparison of error and calculation time of prediction methods

模型方法	负荷预测平均绝对误差/%	光伏预测平均绝对误差/%	算法平均计算时间/s
SARIMA	22.14	17.63	452
LSTM	7.26	5.42	378
SVR	17.66	14.38	965
SD	11.53	9.74	867
PCC-ML	1.47	1.02	545

图 6 给出了通过使用评分-投票机制来识别最优负荷预测模型的过程。首先, 将表 1 给出的 16 个预测任务特征参数输入到训练后的元学习者模型中。然后, 元学习者对每个候选负荷预测模型计算一个分数, 以验证其在解决负荷预测任务时的可行性, 综合比较不同预测模型得到分数, 确定最高分, 然后将分数转换成准确度, 最后综合评价精度等级最高的 PCC-ML 模型为最优负荷预测模型。

特征	数值	特征	数值
1	0.26	9	0.45
2	35	10	1.50
3	0	11	5.65
4	25	12	0.59
5	7	13	0.14
6	0.001	14	5.1
7	1.08	15	21.6
8	3.86	16	96

输出	#1	#2	#3	#4	#5	#6	#7	#8	#9	#10
RF	0.056	0.00	0.00	0.035	0.00	0.00	0.35	0.01	0.00	0.59
KNN	0.00	0.00	0.00	0.2	0.00	0.01	0.4	0.1	0.00	0.2
NB	0.11	0.04	0.01	0.04	0.01	0.01	0.21	0.27	0.03	0.19
LD	0.00	0.11	0.02	0.02	0.23	0.12	0.01	0.01	0.00	0.47

得分精度转换	精确程度	模型推荐
RF	50%	#10 (PCC-ML)
KNN	23%	#7 (LSTM125)
NB	20%	#8 (SVR)
LD	19%	#10 (SARIMA)

图6 评分-投票机制选择负荷预测模型过程示例

Fig.6 An example of a process for selecting a load prediction model by a score-voting mechanism

如图7所示,基于PCC-ML预测方法得到的源荷预测结果,通过列约束生成算法分解形成的主、子问题在经过6次迭代后实现收敛。




图7 列约束生成算法收敛过程

Fig.7 Convergence process of column constraint generation algorithm

如图8所示,从配电网购买电量时,交互电量为正,向配电网出售电量时,交互电量为负,储能设备放电时为正,充电时为负。在00:00—06:00时段内,由于夜间光伏机组不工作,主要通过燃气轮机出力满足用户较低的用电需求,并适当为储能设备充电;在08:00以后,燃气轮机加大出力满足增长的负荷需求,储能设备放电并从配电网购买电量满足用户用电需求;在12:00以后,随着光照强度增强,光伏机组逐渐趋于满出力状




图8 微电网实时调控优化运行情况

Fig.8 Real-time regulation and optimization operation of microgrid

态,能满足区域用户负荷需求,燃气轮机出力逐渐减小,剩余电量为储能设备充电,并向配电网出售电量来增加经济效益;在17:00以后,光照逐渐消失,主要从配电网购买电量满足区域内负荷需求。

如图9所示,微电网预调度阶段各电源设备出力与实际出力存在一定的偏差。但在实时调控阶段,除了08:00时段,本文所提方法对各电源设备实时调控出力与实际出力出现了较小偏差,其余时段均实现高准确度实时调控。




图9 微电网两阶段协调调控效果对比

Fig.9 Comparison of microgrid coordinated regulation effect in two stages

如表3所示,未基于PCC-ML预测方法对源荷进行预测的方法,在日前预调度阶段,其预调度成本低于本文所提方法,其主要原因是未通过预测方法对光伏出力以及负荷进行预测,使得预调度方案在实时调控阶段调控成本和弃光惩罚费用较高。综合两阶段总运行成本,本文所提基于PCC-ML预测方法的两阶段协调预测方法能有效降低微电网运行成本,增加微电网经济收益。

表3 微电网不同方法运行成本对比

Tab.3 Comparison of operating costs in different methods of microgrid

方法	预调度成本/元				实时调控成本/元				两阶段总成本/元	
	燃气轮机	交互功率	储能	预调度成本	燃气轮机	交互	储能系统	弃光惩罚费用		
传统两阶段调度方法	184 867	-139 528	20 566	65 905	51 385	59 452	3 587	9 367	123 791	189 696
基于PCC-ML两阶段方法	177 640	-115 764	13 776	75 652	41 165	3 254	3 200	4 786	52 405	128 057

5 结论

本文提出了一种基于PCC-ML源荷预测方法的微电网两阶段协调优化方法,对微电网中既定的源荷预测任务选择最优预测模型,并通过集成算法的评分投票机制识别最优候选负荷预测模

型,得到最优的微电网源荷预测结果;基于源荷预测结果建立微电网两阶段协调调度优化模型,利用C&CG算法将文章构建的两阶段优化模型分解为主、子问题进行交互迭代求解。最后通过算例分析表明本文所提方法具有较好的准确性,有效地提高了微电网的经济收益。

参考文献

- [1] 赵书强,韩雷,李志伟,等.基于相关机会目标规划的微电网日前优化调度[J].华北电力大学学报,2021,48(2):1-9.
ZHAO Shuqiang, HAN Lei, LI Zhiwei, et al. Day-ahead optimal scheduling of active distribution network by related opportunity goal planning[J]. Journal of North China Electric Power University, 2021, 48(2): 1-9.
- [2] 郭玲,徐青山,郑乐.基于TCN-GRU模型的短期负荷预测方法[J].电力工程技术,2021,40(3):66-71.
GUO Ling, XU Qingshan, ZHENG Le. A forecasting method for short-term load based on TCN-GRU model[J]. Electric Power Engineering Technology, 2021, 40(3): 66-71.
- [3] 许若冰,王璇,赵倩宇,等.基于卷积神经网络和深度置信网络的多类型能源需求预测方法[J].供用电,2020(10):65-70.
XU Ruobing, WANG Xuan, ZHAO Qianyu, et al. A multi-energy demand prediction method based on convolutional neural network and deep belief network[J]. Distribution & Utilization, 2020(10): 65-70.
- [4] 王玥,肖斐,艾芊,等.基于深度置信网络的电能质量扰动事件分类[J].供用电,2019,36(1):40-45,53.
WANG Yue, XIAO Fei, AI Qian, et al. Deep belief networks based classification of power quality disturbance events[J]. Distribution & Utilization, 2019, 36(1): 40-45, 53.
- [5] 贾庆兰.基于概率统计的电力负荷时间序列预测模型[J].现代电子技术,2020,43(21):179-182,186.
JIA Qinglan. Power load time series forecasting model based on probability statistics[J]. Modern Electronics Technique, 2020, 43(21): 179-182, 186.
- [6] 刘明,王红蕾,索良泽.基于变权组合模型的中长期负荷概率密度预测[J].电力系统及其自动化学报,2019,31(7):88-94.
LIU Ming, WANG Honglei, SUO Liangze. Medium-and long-term load probability density forecasting based on variable weight combination model[J]. Proceedings of the CSU-EPSA, 2019, 31(7): 88-94.
- [7] 马松龄,代一楠,徐军昶.改进人工蜂群优化神经网络的短期负荷预测[J].机械设计与制造,2021(7):50-53,57.
MA Songling, DAI Yinan, XU Junchang, et al. Improved short-term load forecasting of artificial bee colony optimization neural network[J]. Machinery Design & Manufacture, 2021(7): 50-53, 57.
- [8] 王淞瑶,张智晟.基于量子加权GRU神经网络的电力系统短期负荷预测[J].电力系统及其自动化学报,2022,34(1):1-7.
WANG Songyao, ZHANG Zhimao. Short-term load forecasting of power system based on quantum weighted GRU neural network[J]. Proceedings of the CSU-EPSA, 2022, 34(1): 1-7.
- [9] 顾雪平,周光奇,李少岩,等.考虑风电预测误差相关性的负荷恢复鲁棒优化[J].电网技术,2021,45(10):4092-4103.
GU Xueping, ZHOU Guangqi, LI Shaoyan, et al. Robust optimization of load restoration scheme considering wind power prediction error correlation[J]. Power System Technology, 2021, 45(10): 4092-4103.
- [10] 朱江行,邹晓松,熊炜,等.基于Prophet与XGBoost混合模型的短期负荷预测[J].现代电力,2021,38(3):325-331.
ZHU Jianghang, ZOU Xiaosong, XIONG Wei, et al. Short-term power load forecasting based on Prophet and XGBoost mixed model[J]. Modern Electric Power, 2021, 38(3): 325-331.
- [11] 苗长新,李昊,王霞,等.基于数据驱动和深度学习的超短期风电功率预测[J].电力系统自动化,2021,45(14):22-29.
MIAO Changxin, LI Hao, WANG Xia, et al. Data-driven and deep-learning-based ultra-short-term wind power prediction[J]. Automation of Electric Power Systems, 2021, 45(14): 22-29.
- [12] 张华强,牟晨东,赵玫,等.基于强化学习的多光储虚拟同步机频率协调控制策略[J].电气传动,2021,51(19):36-42.
ZHANG Huaqiang, MOU Chendong, ZHAO Mei, et al. Frequency coordination control strategy of multiple photovoltaic-battery virtual synchronous generators based on reinforcement learning[J]. Electric Drive, 2021, 51(19): 36-42.
- [13] 徐耀松,段彦强,王雨虹,等.基于相似日选择与改进Stacking集成学习的短期负荷预测[J].传感技术学报,2020,33(4):537-545.
XU Yaosong, DUAN Yanqiang, WANG Yuhong, et al. Short-term load prediction based on similar day selection and improved Stacking integration learning[J]. Chinese Journal of Sensors and Actuators, 2020, 33(4): 537-545.
- [14] 陈锦攀,罗滇生,周勇,等.改进的时变非线性负荷预测组合算法[J].电力系统及其自动化学报,2012,24(1):115-119.
CHEN Jinpan, LUO Diansheng, ZHOU Yong, et al. An improved time-varying nonlinear power load combined forecasting algorithm[J]. Proceedings of the CSU-EPSA, 2012, 24(1): 115-119.
- [15] 张倩,马愿,李国丽,等.频域分解和深度学习算法在短期负荷及光伏功率预测中的应用[J].中国电机工程学报,2019,39(8):2221-2230,5.
ZHANG Qian, MA Yuan, LI Guoli, et al. Applications of frequency domain decomposition and deep learning algorithms in short-term load and photovoltaic power forecasting[J]. Proceedings of the CSEE, 2019, 39(8): 2221-2230, 5.

收稿日期:2021-11-30

修改稿日期:2021-12-15