

考虑联络线负荷匹配特性的供电分区深度迁移学习负荷预测

李吉峰¹, 潘 峰¹, 王延勃¹, 梁贤明¹, 吴 俊¹, 郭思辰²

(1. 国网辽宁省电力有限公司大连供电公司, 辽宁 大连 116001;

2. 国网内蒙古东部电力有限公司扎鲁特旗供电公司, 内蒙古 通辽 028000)

摘要: 合理有效地进行供电分区划分及负荷预测既是挖掘供电潜力、降低电网投资的有效方法, 也是新型电力系统规划与运行的重要基础。针对当前供电分区方法对负荷同时率参数选择的依赖较大, 且未考虑站间联络线的负荷匹配, 以及负荷预测学习方法的精确性仍需进一步提高等问题, 提出了考虑联络线负荷匹配特性的供电分区深度迁移学习负荷预测方法。首先, 构建了供电分区及负荷预测整体技术框架; 其次, 构建了考虑联络线负荷匹配特性的供电分区划分模型, 并提出了相应的求解方法; 在此基础上, 提出了基于深度迁移学习的分区负荷预测方法, 并进一步提出了供电分区划分及负荷预测一体化流程; 最后, 通过实际算例仿真分析验证了所提理论方法的有效性与适用性。

关键词: 特性匹配; 供电分区; 深度迁移学习; 负荷预测

Deep transfer learning load prediction for power supply zones considering the load matching characteristics of contact lines

LI Jifeng¹, PAN Feng¹, WANG Yanbo¹, LIANG Xianming¹, WU Jun¹, GUO Sichen²

(1. China State Grid Liaoning Electric Power Supply Co., Ltd., Dalian Electric Power Supply Company, Dalian 116001, China; 2. China State Grid East Inner Mongolia Electric Power Supply Co., Ltd., Zhaluteqi Electric Power Supply Company, Tongliao 028000, China)

Abstract: The rational and effective zoning of power supply and load prediction is an effective way to exploit the power supply potential and reduce the investment in the power grid, and is also an important basis for the planning and operation of modern power systems. To address the problems that the current power supply zoning method relies heavily on the selection of load simultaneous rate parameters and does not consider the matching of inter-station contact lines, and the accuracy of the load prediction learning method still needs further improvement, a deep transfer learning load prediction method for power supply zones considering the load matching characteristics of contact lines is proposed. Firstly, the overall technical framework of power supply partitioning and load prediction is constructed. Secondly, a model of power supply partitioning considering the matching characteristics of contact line loads is constructed and the corresponding solution method is also proposed. On this basis, a partitioned load prediction method based on deep transfer learning and an integrated process of power supply partitioning and load prediction are proposed. Finally, the validity and applicability of the theoretical method proposed are verified through the simulation analysis of practical cases.

Key words: characteristics matching; power partitioning; deep transfer learning; load prediction

0 引言

随着新型电力系统^[1]构建目标的提出以及建设进程的不断深入,电力系统的电源结构与供电模式均发生了较大的改变。其中,电源结构在向着低碳化与清洁化转型的同时,也对电力的输配环节与设施配置提出了更高的要求;供电模式在向着多样性与灵活性转型的同时,也需要更多新建变电站与线路的支持。然而,对于发展较为成熟的城市电力系统而言,考虑到土地资源紧张以及经济性约束等问题,新建变电站站址与线路通道走廊获取变得较为困难^[2]。因此,在现有设备资源与既定网架结构的基础上,如何合理划分供电分区,并对供电负荷进行精准预测,进而降低系统投资冗余,提升投资精准性,既是当前亟待解决的重要问题,也是未来构建新型电力系统的关键保障。

作为电力规划领域的关键技术,传统的供电分区划分方法主要考虑负荷的实际空间以及地理分布因素,通过宏观的技术原则或人员经验将供电区域划分为若干变电站的集合^[3]。随着供电潜力挖掘需求的不断增长,目前已有研究探索更为精细合理的供电分区划分方法。例如:文献[4]提出了考虑负荷特性互补的供电单元划分评估指标,以及用于供电单元划分的旋转中心线距离加权交替定位算法,在此基础上进一步提出了供电单元内主干线与分支线的组合布线方法;文献[5]通过负荷密度差异提出了一种基于图像处理的供电网格划分方法,提出了网格划分合理性的评价指标;文献[6]综合考虑了用地性质、供电区域和分布式电源等因素的影响,提出了前置和后置两种供电分区划分方法;文献[7]提出了用于中压目标网架规划的供电分区全局优化模型及求解方法,验证了所提方法在有效改善线损、电压合格率和可靠性指标等方面的优势。

作为供电分区划分的重要依据以及衡量源荷匹配性的关键基础,提高负荷预测的精准性也是目前研究的热点。常规的负荷预测通常采用以建筑、用能设备模型驱动的物理建模预测方法^[8]和

以历史数据驱动的数据预测方法^[9]。然而,考虑到模型参数精确性以及数据集合的获取等问题,近几年,已有研究人员将人工智能算法引入到负荷预测研究领域,以增加预测的智能性。例如:文献[10]针对净负荷不确定性较强的问题,通过对不同学习网络的集成,提出了一种基于特征加权改进的Stacking集成学习净负荷预测方法;文献[11]整合了不同时间尺度的历史负荷数据、地区经济数据和气候数据信息,提出了一种堆叠长短期记忆网络模型,实现了负荷的多维度预测;文献[12]结合传统奇异值分解算法和机器学习算法的优势,提出了一种组合预测模型,模型在提升预测效果的同时,还可以对数据的内在特征进行挖掘;文献[13]将负荷历史数据、耦合特征变量及气温等外生变量作为模型输入,构建了面向综合能源系统的基于耦合特征构造及多任务学习的负荷预测方法。

上述文献为本文的研究建立了良好的理论及模型基础,然而,现有的研究仍存在以下问题:

①目前供电分区的划分大多是基于最大负荷预测结果,对同时率参数的选择依赖较大,在进行供电分区划分过程中大多考虑的是站内的源荷匹配性,未考虑站间联络线的匹配问题,供电潜力仍有裕度空间;②目前基于数据驱动的负荷预测方法仍依赖大量的数据样本,对于新建区域难以开展有效的预测,随着负荷用户的不断发展,历史数据的有效性与参考性也会降低。

针对上述问题,本文提出了考虑联络线负荷匹配特性的供电分区深度迁移学习负荷预测方法。首先,构建了供电分区及负荷预测整体技术框架;其次,构建了考虑联络线负荷匹配特性的供电分区划分模型,并提出了相应的求解方法;在此基础上,提出了基于深度迁移学习的分区负荷预测方法,进一步提出了供电分区划分及负荷预测一体化流程;最后,通过实际算例仿真分析验证了本文所提理论方法的有效性与适用性。本文所提方法可以对供电区域进行合理分区及负荷预测,为新型电力系统的规划与运行奠定了良好的负荷分析基础。

1 供电分区及负荷预测框架

本文提出的考虑联络线负荷匹配特性的供电分区深度迁移学习负荷预测框架如图1所示。在供电分区划分方面，本文通过提出负荷特性匹配指标，充分考虑了站内不同负荷点之间的特性匹配关系，以及站间联络线两侧系统的负荷特性匹配关系，从而基于现有供电网络进一步优化供电分区范围，挖掘供电潜力。在负荷预测方面，考虑到负荷数据中所包含的用能行为、电价和天气等外生信息，本文充分发挥卷积神经网络（Convolutional Neural Networks, CNN）^[14]在特征提取方面具有平移不变性和特征提取结果准确的优势，采用CNN模型从数据中提取高维特征，采用深度迁移学习算法^[15]对有限的数据集进行学习，从而保障短期学习的精确性以及长期发展学习的合理性。




图1 供电分区划分及负荷预测框架

Fig. 1 Power supply zoning and load prediction framework

2 考虑联络线负荷匹配特性的供电分区划分

2.1 供电分区划分模型

供电分区划分的主要目的：通过挖掘不同供电线路间负荷特性的匹配关系，提高供电资产的利用率，减少变电站的冗余出线。因此，本文以供电分区数量最少作为首要目标函数。单纯的考虑供电分区数量最少，会导致同时生成多组供电分区数量相同的规划方案，因此，本文在考虑供电分区数量最少目标的基础上，进一步考虑各供电分区内转供线路最大负荷率的均衡性。在降低系统网损的同时，还可以进一步研判供电分区划分的优劣。综上所述，本文所提出的考虑联络线特性匹配的供电分区划分目标函数为

$$\min \Omega \quad (1)$$

$$\Omega = \Omega_{\text{inter}} + \Omega_{\text{exter}} \quad (2)$$

$$\arg \min \sigma^2 = \sum_{i=1}^{\Omega} (\varphi_{i\max} - \bar{\varphi})^2 / \Omega \quad (3)$$

式中， Ω 为供电分区总数； Ω_{inter} 与 Ω_{exter} 分别为站内与站间供电分区数量； σ^2 为各供电分区内转供联络线路最大负荷率的方差，表征各供电分区内转供联络线路最大负荷率之间的均衡性； $\varphi_{i\max}$ 为第*i*个供电分区内转供联络线路的最大负荷率； $\bar{\varphi}$ 为各供电分区内转供联络线路最大负荷率的均值。

在进行供电分区划分时还应考虑以下约束条件。

(1) 转供线路最大负荷率约束

以第*i*个供电分区为例，若供电分区内任意一条线路故障，则非故障线路对故障线路进行联络转供后的最大负荷率应满足

$$\eta_{i\max} = \frac{L_{i\max}}{C_{\max} \cos \phi} \leq 100\% \quad (4)$$

式中， $\eta_{i\max}$ 为第*i*个供电分区内非故障线路的最大负荷率； $L_{i\max}$ 为第*i*个供电分区内负荷时序特性之和的最大值； $C_{\max}$ 为线路最大的传输容量； $\cos \phi$ 为功率因数。

(2) 联络线路负荷率松弛约束

为了充分考虑并挖掘联络线路间的负荷特性匹配程度, 本文将站间联络线路的负荷率设置为一个松弛区间, 而非某种可靠性准则下的刚性约束, 以第 j 条站间联络线路为例, 其负荷率松弛约束为

$$f_{\min} \leq \eta_j = \frac{Y_{j\max}}{C_{\max} \cos \phi} \leq f_{\max} \quad (5)$$

式中, η_j 为第 j 条站间联络线路的负荷率; $Y_{j\max}$ 为第 j 条站间联络线路所带负荷时序特性之和的最大值; $f_{\min}$ 为当前运行方式下根据联络线路所带负荷特性得到的最小负荷率; $f_{\max}$ 为根据联络线路容量参数得到的最大负荷率, 决定了对站间联络线路负荷特性匹配的挖掘程度。

2.2 供电分区划分求解方法

从宏观层面进行分析, 供电分区的划分包括站内与站间。其中, 站内供电分区的划分主要以地理相邻为主要原则, 选定某一组供电线路为基准, 对同一站内的供电范围进行划分, 实现供电线路组内的负荷特性匹配; 而站间的供电分区划分是以单条供电线路的理论最大负荷率为基准, 分别挖掘供电线路的供电能力以及负荷特性, 从而组成合理的供电分区。考虑到站间供电分区的划分受到各座变电站供电范围的影响, 因此, 本文供电分区划分遵循“先站间后站内”的宏观原则。

具体地, 站间供电分区划分是根据供电分区中负荷特性以及供电模型^[16]的要求, 确定变电站站间出线条数, 进而通过站间联络线负荷率的松弛控制进行划分, 以 S_1 、 S_2 两个变电站的一组站间供电分区为例, 具体步骤为:

1) 根据变电站的地理信息, 设定两座变电站站间联络线的初始位置 (分别设为 a_k 、 b_k) 以及负荷率松弛约束 $[f_{\min}, f_{\max}]$ 。

2) 计算不同变电站中负荷点到联络线 a_k 和 b_k 的加权距离, 将加权距离最小的负荷归属进线路 a_k 和 b_k 的供电范围。加权距离与加权因子的计算公式为

$$l_{m,a_k} = l'_{m,a_k} \beta_k \quad (6)$$

$$l_{n,b_k} = l'_{n,b_k} \beta_k \quad (7)$$

$$\beta_k = \left(\frac{\theta_{\max} - \theta_{\min}}{\theta_{\max}} \right)^{\alpha} \quad (8)$$

式中, l'_{m,a_k} 和 l_{m,a_k} 分别为 S_1 站内第 m 个负荷到线路 a_k 的欧式距离和加权距离; l'_{n,b_k} 和 l_{n,b_k} 分别为 S_2 站内第 n 个负荷到线路 b_k 的欧式距离和加权距离; β_k 为加权因子, 与站间联络线路 a_k 和 b_k 组成的供电分区内总负荷时序曲线的峰谷差率有关; α 为加权因子的放大系数; $\theta_{\max}$ 和 $\theta_{\min}$ 分别为负荷点划入线路 a_k 和 b_k 后, 该供电分区内总时序负荷的最大值和最小值, 若负荷加入会增大峰谷差, 则加权因子 β_k 变大, 加权距离变大, 负荷点不利于划分该供电分区, 进而提升供电分区内负荷的匹配性。

3) 将线路 a_k 和 b_k 按照所带负荷的位置进行旋转角度更新, 旋转角度步长设定为 $\Delta \xi$ (本文取 5°), 使得线路通过所带负荷的地理位置中心, 并计算当前划分情况下线路 a_k 和 b_k 负荷率的最大值。

4) 分别判断 a_k 和 b_k 的最大值是否小于预设的负荷率松弛约束。若满足约束, 则输出当前划分结果; 若不满足, 则令 $k=k+1$, 返回步骤2) 重新进行划分。

5) 判断是否达到最大迭代次数, 若达到, 则计算每组供电分区划分方案中转供联络线路的最大负荷率; 若未达到, 则继续进行旋转角度更新, 返回步骤2) 重新进行划分。

6) 输出满足供电分区内转供联络线路负荷率约束的划分方案, 并通过对比各个站间供电分区内负荷同时率均值, 对站间供电分区划分方案进行优选。其中, 假定第 p 个供电分区内负荷的同时率为 τ_p , 定义为第 p 个供电分区内总负荷时序特性的最大值与各个负荷时序特性最大值之和的比值, 具体计算公式为

$$\tau_p = \frac{\max \{ (x_{1,1} + x_{2,1} + \dots + x_{n,1}), \dots, (x_{1,24} + x_{2,24} + \dots + x_{n,24}) \}}{\max(x_{1,1} + x_{1,2} + \dots + x_{1,24}) + \dots + \max(x_{n,1} + x_{n,2} + \dots + x_{n,24})} \quad (9)$$

式中, $x_{n,t}$ 为第 n 个负荷点在时刻 t 的负荷需求。

则 P 个站间供电分区内负荷同时率 $\bar{\tau}$ 的均值表达式为

$$\bar{\tau} = \frac{1}{P} \sum_{p=1}^P \tau_p \quad (10)$$

7) 输出多组站间供电分区划分方案。对于站内供电分区划分而言, 站内供电分区的划分是以站间供电分区划分方案为基础, 具体以变电站为中心, 在站内供电区域以角度均分的原则生成若干中心线, 每两条相邻的中心线互联形成一个站内供电分区; 通过计算每个负荷点到各条中心线的加权距离, 结合不同供电分区转供联络线路约束条件, 将各个负荷点划分进各条中心线的供电分区, 以此保证匹配站内供电分区所带负荷特性。

通过上述步骤即可实现考虑联络线负荷匹配特性的供电分区划分。

3 基于深度迁移学习的分区负荷预测

3.1 深度迁移学习基本原理

在基于负荷特性对供电区域进行分区划分后, 进一步构建基于因果卷积神经网络结构的深度迁移学习负荷预测模型, 对不同分区的负荷进行预测。深度迁移学习负荷预测从宏观上包括源域数据选择、数据离线训练以及数据在线调整三个主要环节, 考虑到源域数据集合的质量与合理性会直接影响深度迁移学习预测的效果, 因此, 本文采用动态时间规整 (Dynamic Time Warping, DTW) [17] 结合JS (Jensen-Shannon) 散度 [18] 来分析不同负荷数据集之间的相关性, 充分发挥DTW在比较时间序列相似度以及JS散度在计算两个序列之间内部特征分布相似度方面的互补优势, 从而有效剔除小概率、低质量与不合理的数据。

DTW分析不同负荷数据集之间相关性的计算公式为

$$\begin{cases} \arg \min_{\varepsilon_1, \varepsilon_2} \|X_1 \varepsilon_1 - X_2 \varepsilon_2\|^2 \\ \text{s.t. } \varepsilon_1 \in \{0, 1\}, \varepsilon_2 \in \{0, 1\} \end{cases} \quad (11)$$

式中, X_1 与 X_2 为两个负荷数据集; ε_1 与 ε_2 为对

应的二进制选择矩阵。

JS散度分析数据集之间内部特征分布相似度的计算公式为

$$\begin{cases} \text{JS}(P_1(X'_1) \| P_2(X'_2)) = \frac{1}{2} \text{KL}\left(P_1 \| \frac{P_1 + P_2}{2}\right) + \\ \quad \frac{1}{2} \text{KL}\left(P_2 \| \frac{P_1 + P_2}{2}\right) \\ \text{KL}(q_1 \| q_2) = \sum q_1(x) \lg \frac{q_1(x)}{q_2(x)} \end{cases} \quad (12)$$

式中, $P(\cdot)$ 与 $q(\cdot)$ 为相应数据集的概率分布。

通过DTW和JS散度的综合应用可以合理评估负荷时间序列之间的相关性, 并指导供电分区负荷预测源域数据集的选择。

3.2 分区负荷预测方法

本文所提基于深度迁移学习的分区负荷预测方法的主要原理: 首先通过DTW结合JS散度筛选合适的源域数据集, 再基于数据集训练模型将训练后的数据集迁移到目标域上的因果卷积神经网络中, 从而进一步通过损失函数目标使得数据集满足预测要求。

假设源域数据集有 N_s 个样本, 即 $\Theta_s = \{x_{1,s}, x_{2,s}, \dots, x_{N_s,s}\}$; 目标域数据集有 N_o 个样本, 即 $\Theta_o = \{x_{1,o}, x_{2,o}, \dots, x_{N_o,o}\}$, 其中, 有 N_o^M 个被标记样本。对源域数据集进行训练的目标是损失函数最小化, 即

$$\min_{\gamma_t, \omega_t} L = L_1 + \frac{\lambda_1}{2} L_2 - \lambda_2 L_3 + \frac{\lambda_3}{2} L_4 \quad (13)$$

$$L_1 = \sum_{v=1}^{N_o^M} L_t(\Lambda_t(x_{v,t}, \gamma_t, \omega_t)) \quad (14)$$

$$L_2 = \left\| \frac{1}{N_o^M} \sum_{v=1}^{N_o^M} \Lambda_t(x_{v,t}) - \frac{1}{N_s} \sum_{w=1}^{N_s} \Lambda_t(x_{w,t}) \right\|^2 \quad (15)$$

$$L_3 = \sum_{v=1}^{N_o^M + N_s} L_h(H(\Lambda_t(x_{v,t}))) \quad (16)$$

$$L_4 = \sum_t (\|\gamma_t\|^2 + \|\omega_t\|^2) \quad (17)$$

式中, λ_1 、 λ_2 和 λ_3 为权重系数; L_1 为带标签的目标负荷数据的预测误差; γ_t 与 ω_t 分别为因果卷积神经网络中神经元的权重和偏置参数; $\Lambda_t(\cdot)$ 函数为对目标域训练的特征提取过程; L_2 为基于最

大平均差计算的源域数据集与目标数据集的特征分布差异； L_3 为源域数据集的分类与惩罚结果； $H(\cdot)$ 函数为源域分类器；为防止过拟合，引入权重的正则化函数 L_4 作为损失函数的一部分。

针对上述优化问题，本文具体采用随机梯度下降法对问题进行求解，其中，梯度的计算公式为

$$\begin{cases} \nabla \gamma_t = \frac{\partial L_1}{\gamma_t} \\ \nabla \omega_t = \frac{\partial L_1}{\omega_t} \end{cases} \quad (18)$$

本文所提出的基于深度迁移学习的分区负荷预测方法主要包括模型相关性分析及离线训练阶段和基于损失函数调整阶段。其中，在模型相关性分析及离线训练阶段，所获取的结果参数是

根据源域数据集所得的全局参数；而在基于损失函数调整阶段，所获取的结果参数是根据时间序列及标记所得的局部参数。因此，本文所提方法及所构建的模型具有全局参数和局部参数的混合效果。

3.3 供电分区划分及负荷预测一体化流程

本文所提出的考虑联络线特性匹配的供电分区负荷深度迁移学习预测方法主要包括站间供电分区划分、站内供电分区划分、数据样本模型相关性分析、离线训练阶段以及预测数据损失函数调整阶段等主要步骤，具体的一体化流程如图2所示。




图2 供电分区划分及负荷预测一体化流程

Fig. 2 Integrated process for electricity supply zoning and load forecasting

4 算例分析与对比

4.1 算例概况

以中国东北地区某城市实际地理结构为例，具体的地理、街道及负荷分布如图3所示。区域内包含3座 $2 \times 180 \text{ MV} \cdot \text{A}$ 变电站，电压等级为220 kV，所组成的供电区域内共有160个负荷点。其中，工业负荷点34个，商业负荷点57个，居民负荷点69个，不同类型负荷的典型日负荷曲线如图4所示。算例中不同变电站之间的联络线路主要包含LGJ三种型号，安全电流分别为445 A、610 A和845 A，电压等级为66 kV。下面将基于算例设置对供电分区划分及负荷预测结果进行分析。




图3 系统地理及负荷分布

Fig. 3 System geography and load distribution




图4 不同类型负荷典型日负荷曲线
Fig. 4 Typical daily load curves for different types of loads

4.2 供电分区划分结果分析

为验证本文所提方法的有效性，具体采用三种不同思路对区域进行供电分区划分。三种供电单元划分方法为：

- 1) 仅考虑单条线路所带负荷的特性匹配，不考虑站间联络线路的负荷特性匹配。
- 2) 考虑站间联络线路的负荷特性匹配，不考虑站间线路的松弛负荷率控制，将站间线路的最大负荷率设定为50%。
- 3) 考虑站间联络线路的负荷特性匹配，并对站间线路进行松弛负荷率控制。

基于4.1节的算例设置，不同方案下变电站的出线条数及供电线路的负荷率对比情况见表1。由表1可知，在变电站出线总条数方面，相比较于方案1与方案2，方案3通过对站间联络线进行松弛负荷率的控制来划分供电分区，结合负荷特性匹配可以节省约32.7%与18.6%的出线条数，进而节省了建设投资。在各供电分区内联络线路最大负荷率方面，方案3充分利用了工业负荷、商业负荷与居民负荷在负荷峰谷差方面的特性互补，从而将特性匹配的负荷划分在同一供电分区内；进一步结合站间联络线路的负荷特性匹配以及松弛负荷率控制，充分挖掘了站间线路的供电能力，使得每条站间线路可以带更多数量的负荷，有效提升了供电线路的资产利用效率。

表1 不同方案供电分区划分结果对比
Tab. 1 Comparison of zoning results for different cases

方案	变电站出线总条数 / 条	各供电分区内联络线路最大负荷率区间 (%)	各供电分区内联络线路平均负荷率 (%)
1	52	[47.8, 51.3]	49.6
2	43	[69.8, 73.2]	71.5
3	33	[70.5, 78.7]	74.6

以方案3为例，具体的供电分区划分结果如图5所示。由图5可知，每座变电站的站内供电线路条数为8条，站间供电线路条数为3条，3座变电站供电线路条数为33条。各个供电分区的供电范围清晰且独立，符合相关规划设计导则中对供电分区划分的要求。




图5 方案3供电分区划分结果
Fig. 5 Case 3 power supply zoning results

4.3 分区负荷预测结果分析

在对供电区域进行分区的基础上，本文进一步对分区内的负荷进行预测，从而为运行与规划方案的制定提供参考。以4.2节方案3所得到的供电分区划分结果为基础，对不同供电分区近一年的负荷数据进行学习，通过DTW和JS散度的综合应用保证数据的关联性，剔除不良数据，以S₁的供电区域为例，不同季节典型日负荷预测曲线如图6所示。




图6 不同季节典型日负荷预测曲线

Fig. 6 Typical daily load forecasting curves for different seasons

由图6可知,通过对供电范围进行分区划分,可以有效地将负荷进行匹配,从而降低负荷波动峰谷差,结合本文所提出的深度迁移学习负荷预测方法,可以有效地对不同季节的负荷进行预测。在此基础上,本文进一步通过平均绝对百分比误差 (Mean Absolute Percentage Error,

MAPE) 和最大相对百分比误差 (Maximum Relative Percentage Error, MRPE) 两个指标^[19],将所提出的深度迁移学习负荷预测方法与常规趋势外推的数据驱动方法以及神经网络负荷预测方法^[20]进行对比,以反映不同方法的预测准确度,具体对比结果见表2。

由表2可知,面对波动性大、随机性较强的负荷时序预测问题,数据趋势外推方法易受到不良数据的影响,预测误差较大;基于神经网络的预测方法虽然可以实现数据的学习,但是无法避免不良与尖峰负荷数据带来的预测误差问题。本文提出的基于深度迁移学习的负荷预测方法,首先通过DTW和JS散度的综合应用剔除不良与小概率数据,进而对数据进行充分学习,预测准确度较高。

表2 不同方法预测精度对比

Tab. 2 Comparison of the prediction accuracy of different methods

算法	春季		夏季		秋季		冬季	
	MAPE	MRPE	MAPE	MRPE	MAPE	MRPE	MAPE	MRPE
趋势外推	9.210 7	13.921 1	10.213 6	14.728 5	10.201 8	14.511 2	10.201 1	14.925 6
神经网络	2.218 5	4.012 7	2.572 3	4.980 2	2.331 8	3.879 2	2.563 1	4.620 1
本文方法	1.072 8	2.663 1	1.211 9	2.952 3	1.107 3	2.764 2	1.201 3	2.932 8

单位: (%)

5 结束语

本文针对供电区域的分区划分及负荷预测问题,提出了考虑联络线负荷匹配特性的供电分区深度迁移学习负荷预测方法,通过理论分析与实际算例仿真验证,得到的主要结论为:

1) 在供电分区划分的环节中,考虑联络线路的负荷匹配特性,可以进一步挖掘供电潜力,减少变电站出线条数,从而降低相应的投资冗余。

2) 相比较于数据趋势外推及神经网络负荷预测方法,本文所提出的基于深度迁移学习的负荷预测方法可以有效剔除不良数据,预测准确度较高。

未来的研究将会进一步分析不同用能行为、需求响应特性以及高比例新能源接入对供电分区划分及负荷预测产生的影响。

参考文献

- [1] 张智刚,康重庆.碳中和目标下构建新型电力系统的挑战与展望[J].中国电机工程学报,2022,42(8):2806-2819.
- [2] 刘洪,李吉峰,张家安,等.考虑可靠性的中压配电系统供电能力评估[J].电力系统自动化,2017,41(12):154-160.
- [3] 伍也凡,刘浩田,肖振锋,等.考虑源-网-荷不确定性的增量配电网规划研究综述[J].电力系统保护与控制,2021,49(8):177-187.
- [4] 葛少云,蔡期源,刘洪,等.考虑负荷特性互补及供电单元划分的中压配电网实用化自动布线[J].中国电机工程学报,2020,40(3):790-802.
- [5] 陈志鹏,谢宁,王承民,等.基于图像处理的配电网差异性网格划分方法研究[J].智慧电力,2020,48(1):49-54,62.

- [6] 陈哲,王主丁,黄河,等.中压配电网规划中计及多因素影响的供电分区划分方法[J].电网技术,2020,44(12):4636-4643.
- [7] 张漫,王主丁,李强,等.中压目标网架规划中供电分区优化模型和方法[J].电力系统自动化,2019,43(16):125-135.
- [8] 葛少云,李吉峰,刘洪,等.考虑物理特征与行为因素的家庭用能特性建模[J].电力自动化设备,2019,39(3):36-44.
- [9] 朱继忠,董瀚江,李盛林,等.数据驱动的综合能源系统负荷预测综述[J].中国电机工程学报,2021,41(23):7905-7923.
- [10] 鲍海波,吴阳晨,张国应,等.基于特征加权Stacking集成学习的净负荷预测方法[J].电力建设,2022,43(9):104-116.
- [11] 罗澍忻,麻敏华,蒋林,等.考虑多时间尺度数据的中长期负荷预测方法[J].中国电机工程学报,2020,40(S1):11-19.
- [12] 杨维熙,刘勇,舒勤.基于补充集合经验模态分解的短期负荷预测模型[J].电网技术,2022,46(9):3615-3622.
- [13] 吕忠麟,顾洁,孟璐.基于耦合特征与多任务学习的综合能源系统短期负荷预测[J].电力系统自动化,2022,46(11):58-66.
- [14] 李宗博,焦在滨,何安阳.基于卷积神经网络特征迁移策略的变压器智能保护方法[J].中国电机工程学报,2021,41(15):5201-5211.
- [15] 杨秀,吴吉海,孙改平,等.基于深度学习和迁移学习的公共楼宇非侵入式负荷分解[J].电网技术,2022,46(3):1160-1168.
- [16] 葛少云,孙昊,刘洪,等.考虑可靠性与故障后负荷响应的主动配电网供电能力评估[J].电力系统自动化,2019,43(6):77-84,91.
- [17] 杨健,徐思卿,姜尚光,等.基于动态时间规整的风电功率爬坡滚动修正模型[J].电力系统自动化,2021,45(16):152-159.
- [18] 王炜,李伟梅,何淼,等.基于JS-散度的不确定概率约束优化方法[J].吉林师范大学学报(自然科学版),2018,39(2):54-58.
- [19] 何耀耀,刘瑞,撒奥洋.基于实时电价与支持向量分位数回归的短期电力负荷概率密度预测方法[J].中国电机工程学报,2017,37(3):768-775.
- [20] 向德军,张维静,冯歆尧,等.考虑特征值细分的广义加性短期负荷预测模型[J].电力需求侧管理,2023,25(1):46-51.

作者简介

李吉峰(1991—),男,博士,工程师,研究方向为城市电网规划及电力系统可靠性。

潘峰(1983—),男,硕士,高级工程师,研究方向为电力系统调度及电力监控。

(收稿日期:2023-03-24)