

DOI: 10.12158/j.2096-3203.2026.03.013

数据模型双驱动的负荷调节潜力评估及预测方法

赵艳, 柳伟, 唐鹏程, 宋莉娟, 赵艺琳, 于学畅

(南京理工大学自动化学院, 江苏 南京 210094)

摘要:在高比例光伏配网的新形势下,研究负荷可调节潜力对于电网安全稳定和调度精益化具有积极作用。为此,文中提出一种基于数据模型双驱动的负荷调节潜力评估及预测方法。首先,构建负荷调节潜力多维评估指标体系及评估模型,提出 k -均值(k -means)算法负荷特征提取和自组织映射(self-organizing map, SOM)算法调节潜力特征融合的二次聚类方法,实现对各类负荷时序调节潜力的评估;然后,提出融合双向长短期记忆(bidirectional long short-term memory, BiLSTM)神经网络和动态模式分解(dynamic mode decomposition, DMD)的负荷调节潜力智能预测方法,实现对未来24 h 15 min级负荷调节潜力的预测;最后,使用某地负荷数据对所提策略开展仿真验证,评估结果验证了所提评估与预测方法的有效性,表明BiLSTM-DMD模型具有较高的预测精度。

关键词:数据模型双驱动;负荷调节潜力;潜力评估;智能预测;二次聚类;神经网络

中图分类号:TM714

文献标志码:A

文章编号:2096-3203(2026)03-0116-11

0 引言

近年来,全球气候变暖和环境污染问题日益严重,各国积极推动低碳清洁能源转型,光伏或将成为能源转型的核心力量^[1-2],大量光伏电站的建设可以减轻环境压力,促进地方经济发展。然而,光伏出力的随机性和波动性带来的有功功率不确定性、电压波动等问题,给配电网的整体规划、精准调度以及安全运行带来巨大挑战^[3-6]。通过研究负荷调节潜力评估预测技术,可以掌握高比例光伏配电网地区负荷的上调和下调能力,有助于实现削峰填谷,有效平衡电网负荷,显著提高电网的安全稳定性和调度的精益化水平^[7-12]。

当前,针对负荷可调节潜力的研究主要从充分挖掘负荷特性和用户用电行为特性出发,对调节潜力开展分析。文献[13]从历史用电数据中挖掘出小时级居民需求响应潜力信息,针对缺少历史响应数据支撑的情形,提出一种基于高斯混合模型的聚合响应潜力评估方法。文献[14-17]制定一套基于“可观、可测、可调、可控”4个维度的评估体系,针对不同类型的用户场景,建立负荷调控能力评估标准及评估流程。文献[18]利用错时、轮休和错峰潜力构建多维负荷指标,并利用信息熵和逼近理想解排序法量化工业用户负荷调控潜力。文献[19]研究多维特征下的多类型负荷调度优化系统,并构建适用于多类型负荷的时序调节控制模型。文献[20]根据实际电力需求,综合考虑用户特征,建立负荷调控价值指标体系,并提出基于灰靶-前景理论

的量化方法,分析用户的检修、轮休、错时和错峰潜力,并通过模糊评判法进行综合评估。

文献[21-22]采用神经网络组合模型预测负荷可调潜力,为负荷潜力的研究提供了新的思路。文献[23]提出一种基于变分模态分解、深度信念网络和差分自回归移动平均模型的组合预测模型,对短期电力负荷进行预测。文献[24]为提高配电网超短期负荷预测精度,提出一种基于先知和双重多头自注意力-时间卷积网络的超短期负荷预测框架。文献[25]建立基于灰色关联度的局部加权回归预测模型,并用粒子群算法优化局部加权回归模型参数。目前关于潜力预测的研究较少,大多是对过去短期负荷可调潜力的预测,并不能获得未来时刻负荷的可调潜力。

文中结合多维度评估体系分析方法和神经网络预测方法的优点,提出数据模型双驱动的负荷调节潜力分析方法,将指标量化、负荷聚类、模型评估、未来预测相融合,不仅能对各类负荷当前调节潜力进行评估,还能对各类负荷未来时刻的调节潜力进行预测。首先,构建负荷调节潜力多维指标体系,并利用 k -均值(k -means)算法和自组织映射(self-organizing map, SOM)算法相结合的二次聚类算法对负荷进行分类,实现考虑潜力指标影响的负荷精准分类。然后,构建负荷调节潜力物理评估模型,代入指标及各参数进行计算,获得各类负荷调节潜力评估结果。最后,提出双向长短期记忆(bidirectional long short-term memory, BiLSTM)神经网络和动态模式分解(dynamic mode decomposition, DMD)相结合的负荷调节潜力预测方法,通过评估结果提

收稿日期:2025-07-17;修回日期:2025-09-14

基金项目:国家自然科学基金资助项目(52077103)

供的数据支撑未来时刻的调节潜力预测。经算例验证,所提预测方法能达到较高精度。

1 数据模型双驱动的负荷调节潜力评估

1.1 负荷调节潜力指标体系

文中通过建立评估指标体系,量化各种因素对负荷调节潜力的影响,为后续调节潜力的评估和预测提供数据支持。评估指标体系如图1所示,包括自然环境、负荷特征和用户行为3个关键维度。

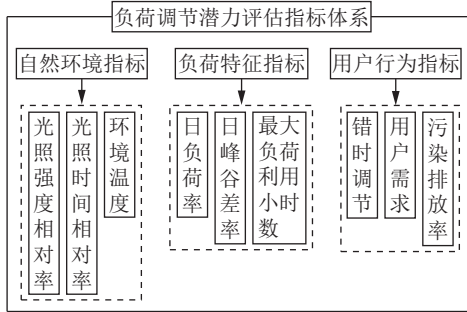


图1 负荷调节潜力评估指标体系

Fig.1 Load regulation potential assessment index system

1.1.1 自然环境指标

(1) 光照强度相对率 C_1 为光照强度与过去 30 d 最高光照强度的比值,计算如下:

$$C_1 = \frac{E_{\text{day}}}{E_{\text{max},30}} \times 100\% \quad (1)$$

式中: E_{day} 为当日光照强度; $E_{\text{max},30}$ 为过去 30 d 最高光照强度。

(2) 光照时间相对率 C_2 用于评估光伏发电的发电时间,其值越高表示发电时间越长、调节潜力越大,计算如下:

$$C_2 = \frac{T_d}{24} \times 100\% \quad (2)$$

式中: T_d 为当天的光照小时数。

(3) 环境温度 C_3 。不同的环境温度条件会直接影响能源系统的运行效率和负荷需求模式。在夏季和冬季,负荷的调节潜力会比其他季节大。

1.1.2 负荷特征指标

(1) 日负荷率 C_4 用于评估全天的负荷利用效率,计算如下:

$$C_4 = \frac{P_{\text{ave}}}{P_{\text{peak}}} \quad (3)$$

式中: P_{ave} 为每日利用负荷平均值; P_{peak} 为每日利用负荷最大值。

(2) 日峰谷差率 C_5 描述每日内用户负荷的峰值和谷值之间的差异程度,反映高峰时段与低谷时段的电力需求差异。日峰谷差率的值越大,表明负荷可调节潜力越大,计算如下:

$$C_5 = \frac{P_{\text{peak}} - P_{\text{min}}}{P_{\text{peak}}} \quad (4)$$

式中: P_{min} 为每日利用负荷最小值。

(3) 最大负荷利用小时数 C_6 为某个时间段内(通常为 1 a)用户用电量达到年最大负荷的时长总和,用来衡量各类用户负荷在其最高负荷状态下的运行时间总和。

1.1.3 用户行为指标

(1) 错时调节 C_7 用于合理安排不同用户或设备的运行时间,将能源消耗从高峰时段移至低谷时段,以平衡负荷峰谷差异,计算如下:

$$\begin{cases} C_7 = a_{\tau} (P_{\text{peak}} - \min(P_{\text{dL}}, P_{\text{dL}})) \\ a_{\tau,\text{up}} = \begin{cases} 0 & \text{高峰期} \\ 1 & \text{低谷期} \end{cases} \\ a_{\tau,\text{down}} = \begin{cases} 1 & \text{高峰期} \\ 0 & \text{低谷期} \end{cases} \end{cases} \quad (5)$$

式中: a_{τ} 为错时调节意愿系数; $a_{\tau,\text{up}}$ 、 $a_{\tau,\text{down}}$ 分别为 a_{τ} 上调与下调情况下的取值; P_{dL} 、 P_{dL} 分别为高峰时段提前或者推迟 L 小时的用户负荷, L 根据电网高峰的持续时间确定。

(2) 用户需求 C_8 用于表示用户生产生活行为需求的约束。一般情况下,用户在高峰时期会通过减少可中断负荷降低用电量,但会保留一定的必要负荷以保障设备的正常运行;在其他用电时段,用户可以在保障自身舒适度并且不造成资源浪费的前提下,开启一些设备,以使该地区总负荷曲线更加平稳。

$$\begin{cases} C_8 = \begin{cases} P_{\text{ave,d}}(t) - P_{\text{est}} & \text{向下调节} \\ P_{\text{inc}} - P_{\text{ave,d}}(t) & \text{向上调节} \end{cases} \\ P_{\text{est}} = P_{\text{min},30}(t) \\ P_{\text{inc}} = P_{\text{max},30}(t) \end{cases} \quad (6)$$

式中: $P_{\text{ave,d}}(t)$ 为用户过去 30 d t 时刻平均用电量; P_{est} 为用户生产生活保障负荷; P_{inc} 为用户生产生活最高负荷; $P_{\text{min},30}(t)$ 为过去 30 d t 时刻内的最低负荷; $P_{\text{max},30}(t)$ 为过去 30 d t 时刻内的最高负荷。

(3) 污染排放率 C_9 为某用户过去 30 d 内的平均污染物排放量占该地区过去 30 d 内污染物排放量总和的比重,用来判断当前用户是否具有调节潜力,计算如下:

$$C_9 = \frac{G_{\text{ave},30}}{G_m} \quad (7)$$

式中: $G_{\text{ave},30}$ 为某用户过去 30 d 内的平均污染物排放量; G_m 为该地区过去 30 d 污染物排放量的总和。

1.2 基于 k -means 和 SOM 的二次聚类模型

首先,通过 k -means 对负荷数据进行初次聚类,

将具有相似负荷特征的负荷数据分为一类。然后,将负荷调节潜力影响因素与一次聚类结果融合,利用SOM神经网络的模式分类性能进行二次聚类,得到包含负荷可调潜力信息的聚类结果,模型结构如图2所示。

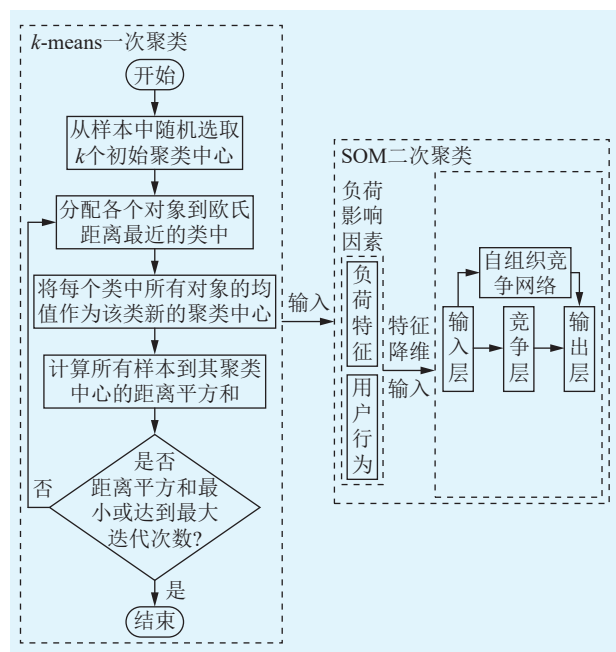


图2 基于k-means和SOM的二次聚类模型流程
Fig.2 The process of the two-layer clustering model based on k-means and SOM

(1) 通过k-means算法对负荷数据初步聚类,最佳聚类数k采用轮廓系数 S_c 决定,轮廓系数越大代表簇内样本越紧凑、簇间距离越大、聚类效果越好^[26]。轮廓系数计算如下:

$$\begin{cases} s_i = \frac{b_i - a_i}{\max(a_i, b_i)} \\ S_c = \frac{\sum_{i=1}^N s_i}{N} \end{cases} \quad (8)$$

式中: s_i 为第*i*个簇内单个样本的轮廓系数; a_i 为第*i*个簇内某个样本与其他样本的平均距离; b_i 为第*i*个簇内某个样本与其他簇样本的平均距离; N 为簇的个数。

(2) 负荷特征指标和用户行为指标数据繁杂,首先采用主成分分析法(principal component analysis, PCA)对指标数据进行降维。然后,将指标数据与一次聚类结果作为SOM输入,采用SOM进行二次聚类^[27],具体步骤如下。

步骤1:对主成分 X^* 进行归一化处理;对竞争层中的权向量 W_j 进行初始化和归一化,其中 $j=1,2,\dots,m$, m 为竞争层神经元的数量。对学习率 $\eta \in (0,1)$ 赋初值。

步骤2:计算 X^* 与每个神经元权向量间的欧式距离,将最相近的神经元定义为胜利神经元,并将胜利神经元的权重向量替代为权向量更新值 W_{j^*} 。

$$\|X^* - W_{j^*}\| = \min \sqrt{(X^* - W_j)^T (X^* - W_j)} \quad (9)$$

步骤3:获胜神经元输出为1,其余输出为0,并对获胜神经元进行权向量调整。

$$\begin{cases} O_j(t+1) = \begin{cases} 1 & j = j^* \\ 0 & j \neq j^* \end{cases} \\ W_{j^*}(t+1) = W_{j^*}(t) + \eta(t)(X^* - W_{j^*}) & j = j^* \\ W_j(t+1) = W_j(t) & j \neq j^* \end{cases} \quad (10)$$

式中: $O_j(t+1)$ 为*t*+1时刻第*j*个神经元的输出; j^* 为获胜神经元的编号; η 随着权向量更新的过程逐渐减小。

重复步骤1—步骤3,直到 η 衰减到0时,停止迭代,输出结果。

1.3 负荷调节潜力评估模型

基于1.1节得到的3类调节潜力指标,将指标数据归一化,构建负荷调节潜力评估模型。

$$\begin{cases} P_{up}(t) = \sum_{\alpha=1}^9 w_{u,\alpha} C_{\alpha}(t) \Delta P_{up}(t) + P(t) \\ \Delta P_{up}(t) = P_{max,30}(t) - P_{ave,d}(t) \\ P_{down}(t) = \sum_{\alpha=1}^9 w_{d,\alpha} C_{\alpha}(t) \Delta P_{down}(t) + P(t) \\ \Delta P_{down}(t) = P_{min,d}(t) - P_{ave,30}(t) \end{cases} \quad (11)$$

式中: $P_{up}(t)$ 、 $P_{down}(t)$ 分别为*t*时刻负荷调节潜力的上限和下限; $\Delta P_{up}(t)$ 为*t*时刻可上调的负荷变化量; $\Delta P_{down}(t)$ 为*t*时刻可下调的负荷变化量; $w_{u,\alpha}$ 、 $w_{d,\alpha}$ 分别为第*α*个指标上调和下调的权重,每类负荷的权重值设置不同,取值范围为(0,1]; C_{α} 为第*α*个指标负荷归一化后的指标值; $P(t)$ 为*t*时刻的负荷值。

1.2节所提的二次聚类模型可以对各类负荷数据进行区分,结合上述评估模型便可以对某个地区各个时刻不同类别负荷的调节潜力开展评估。

2 基于数据驱动的负荷调节潜力预测方法

2.1 精度评价指标

文中采用平均绝对误差百分比(mean absolute percentage error, MAPE)和均方根误差(root mean square error, RMSE)衡量模型预测精度^[28]。MAPE评估模型的整体预测精度,RMSE衡量预测误差的波动。MAPE和RMSE数值越低,预测效果越好。MAPE、RMSE的计算表达式分别如式(12)、式(13)所示。

$$E_{MAPE} = \frac{1}{\theta} \sum_{t=1}^{\theta} \frac{|Q_t^* - Q_t|}{Q_t} \times 100\% \quad (12)$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{\theta} \sum_{t=1}^{\theta} (Q_t^* - Q_t)^2} \quad (13)$$

式中: E_{MAPE} 为 MAPE 值; E_{RMSE} 为 RMSE 值; θ 为样本个数; Q_t^* 、 Q_t 分别为 t 时刻调节潜力的预测值和评估值。

2.2 基于 BiLSTM-DMD 的负荷调节潜力预测模型

提出一种基于 BiLSTM 初步预测和 DMD 误差修正的负荷调节潜力预测方法, 通过 1.3 节得出的评估结果对未来 24 h 15 min 级的负荷调节潜力进行预测, 预测方法如图 3 所示, 图中横坐标表示时间节点, 每相邻两个节点间的时间间隔为 15 min, 24 h 可分为 96 个时间节点。

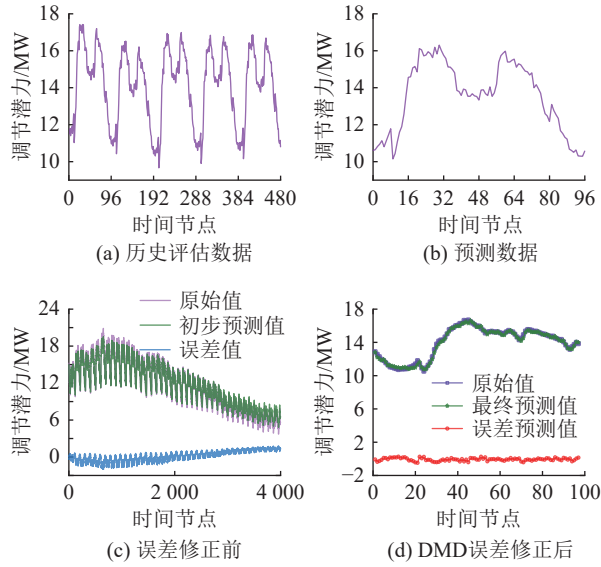


图 3 负荷调节潜力预测方法

Fig.3 Load regulation potential prediction method

整体预测主要有以下 4 个步骤。

步骤 1: 数据归一化和聚类分析。对负荷数据和各类指标数据进行归一化, 通过 k -means 和 SOM 二次聚类模型对负荷用户数据进行聚类。

步骤 2: 负荷调节潜力评估。针对步骤 1 中得到的聚类结果, 对各类用户进行负荷调节潜力评估计算, 得到各用户负荷调节潜力的上限和下限。

步骤 3: BiLSTM 初步预测。对步骤 2 得到的负荷调节潜力评估结果进行预测, 用前 5 d 评估数据预测未来 24 h 负荷调节潜力数据。

步骤 4: DMD 修正预测误差。对步骤 3 得到的预测误差进行 DMD 重构, 得到新的误差值, 并获得最终预测结果。

2.2.1 基于 BiLSTM 的初步预测

BiLSTM 对时间依赖性较强的时序数据处理能力较好, 因此对文中的时序负荷预测可以得到较好

的效果。BiLSTM 由前向长短期记忆(long short-term memory, LSTM)神经网络和反向 LSTM 组成, 通过对前向和反向 LSTM 的输出结果向量进行拼接, 得到最终的输出结果^[29]。

BiLSTM 基本循环单元 LSTM 网络采用输入门、输出门和遗忘门来控制信息的选择性流动^[30]:

$$\begin{aligned} f_t &= \sigma(W_f x_t + U_f h_{t-1} + b_f) \\ i_t &= \sigma(W_i x_t + U_i h_{t-1} + b_i) \\ o_t &= \sigma(W_o x_t + U_o h_{t-1} + b_o) \\ c_t &= f_t \odot c_{t-1} + i_t \odot g_t \\ h_t &= o_t \odot \tanh(c_t) \\ g_t &= \tanh(W_g x_t + U_g h_{t-1} + b_g) \end{aligned} \quad (14)$$

式中: f_t 、 i_t 、 o_t 分别为 t 时刻门控机制的遗忘门、输入门和输出门, 其模长在 0~1 之间; c_t 为 t 时刻的记忆单元; h_t 为 t 时刻隐藏层的外部状态; g_t 为 t 时刻通过双曲正切函数得到的候选状态; σ 为激活函数; x_t 为当前时刻的输入; c_{t-1} 、 h_{t-1} 分别为 $t-1$ 时刻的记忆单元和隐藏层的外部状态; U_f 、 U_i 、 U_o 、 U_g 分别为遗忘门、输入门、输出门和候选状态中隐藏层之间的权值矩阵; W_f 、 W_i 、 W_o 、 W_g 分别为隐藏层与输入层之间的权值矩阵; b_f 、 b_i 、 b_o 、 b_g 为偏置矩阵; \odot 为矩阵或向量中对应位置元素相乘。

BiLSTM 结构如图 4 所示, 其中 x_β 、 y_β 分别为各个时间步的输入和输出, 其中 $\beta = 1, 2, \dots, n$, n 为时间步; \otimes 为向量乘; \oplus 为向量和。

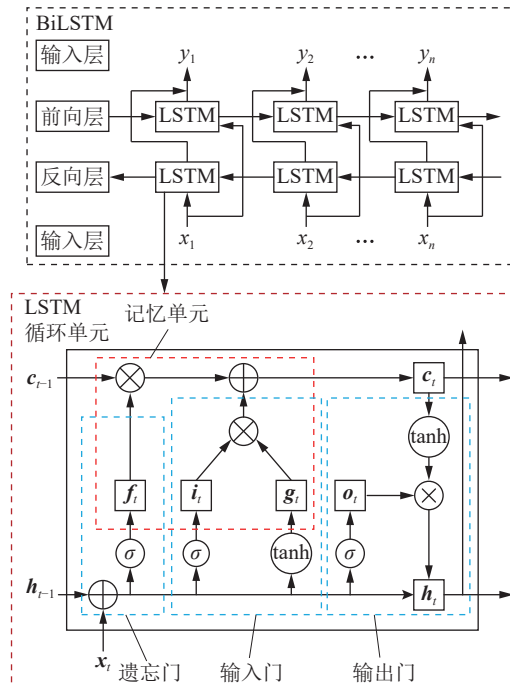


图 4 BiLSTM 结构

Fig.4 The structure of BiLSTM

2.2.2 基于 DMD 的预测修正

DMD 是一种数据驱动算法,其特点在于从流动数据中提取复杂的时空特征。DMD 不仅可以分析系统内部运行情况,还可以用于预测系统的未来状态^[31-32],基于 DMD 的误差预测过程如下。

(1) 构造误差矩阵。

将误差序列 \mathbf{E} 归一化, $\mathbf{E}=[e_1 e_2 \cdots e_\gamma \cdots e_n]$, e_γ 为第 γ 时刻的误差;任意两相邻误差之间的时间间隔 Δt 为 15 min。将序列 \mathbf{E} 转化为一个窗口长度为 $l(2 \leq l \leq n/2)$ 且重叠段数为 $K(K=n-l+1)$ 的多维矩阵 \mathbf{E}^* 。

$$\mathbf{E}^* = [e_1^* \ e_2^* \ \cdots \ e_l^*] = \begin{bmatrix} e_1 & e_2 & \cdots & e_l \\ e_2 & e_3 & \cdots & e_{l+1} \\ \vdots & \vdots & \ddots & \vdots \\ e_K & e_{K+1} & \cdots & e_{K+l-1} \end{bmatrix} \quad (15)$$

式中: e_γ^* 为第 γ 时刻的估算误差。

(2) 误差的模式分解。

假定存在一个映射矩阵 \mathbf{A} , 使连续向量间满足 $\mathbf{E}_2^* = \mathbf{A}\mathbf{E}_1^*$, 其中, \mathbf{E}_1^* 、 \mathbf{E}_2^* 分别为当前时刻和下一时刻的快照矩阵, \mathbf{A} 描述了误差系统的动态特性。

对 \mathbf{E}_1^* 进行奇异分解:

$$\begin{cases} \mathbf{E}_1^* = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^H \\ \mathbf{A} = \mathbf{U}\mathbf{B}\mathbf{U}^H \\ \mathbf{B} = \mathbf{W}\mathbf{D}\mathbf{W}^{-1} \\ \mathbf{D} = \text{diag}(\mu_1, \mu_2, \cdots, \mu_r) \end{cases} \quad (16)$$

式中: \mathbf{U} 、 \mathbf{V}^H 为奇异向量; \mathbf{V} 为奇异值分解中的右奇异向量矩阵; \mathbf{V}^H 、 \mathbf{U}^H 分别为 \mathbf{V} 、 \mathbf{U} 的伴随矩阵; $\mathbf{\Sigma}$ 为 \mathbf{E}_1^* 的奇异值对角矩阵; \mathbf{B} 为相似变换矩阵; \mathbf{D} 为 \mathbf{B} 奇异值的对角矩阵; μ_ξ 为第 ξ 个误差模式的误差特征值, $\xi = 1, 2, \cdots, r$, 其中 r 为误差模式的数量; \mathbf{W} 为误差特征向量 \mathbf{w}_ξ 的矩阵。

通过上述分解,提取出误差的动态模式,并利用矩阵 \mathbf{B} 估计误差的变化。

(3) 重构误差序列。

e_γ^* 的表达式如式(17)所示。

$$e_\gamma^* = \mathbf{A}e_{\gamma-1}^* = \mathbf{U}\mathbf{B}\mathbf{U}^H e_{\gamma-1}^* = \mathbf{U}\mathbf{W}\mathbf{D}^{\gamma-1} \mathbf{W}^{-1} \mathbf{U}^H e_1^* \quad (17)$$

将误差模式的幅值向量定义为:

$$\boldsymbol{\alpha} = \mathbf{W}^{-1} \mathbf{U}^H e_1^* \quad (18)$$

结合第 ξ 个误差模式的基向量 $\boldsymbol{\Phi}_\xi = \mathbf{U}\mathbf{w}_\xi$, 任意时刻重构的误差 e_γ^* 为:

$$e_\gamma^* = \sum_{\xi=1}^r \boldsymbol{\Phi}_\xi \alpha_\xi (\mu_\xi)^{\gamma-1} \quad (19)$$

式中: α_ξ 为第 ξ 个误差模式的幅值。

重构窗口长度为 $p(p > r)$ 的误差时序矩阵 \mathbf{E}_R^* :

$$\mathbf{E}_R^* = \begin{bmatrix} e_{R(1)}^* & e_{R(2)}^* & \cdots & e_{R(p)}^* \end{bmatrix} = \boldsymbol{\Phi} \boldsymbol{\alpha} \mathbf{V}_{\text{and}}(p) = \begin{bmatrix} \boldsymbol{\Phi}_1 & \boldsymbol{\Phi}_2 & \cdots & \boldsymbol{\Phi}_r \end{bmatrix} \text{diag}(\alpha_1, \alpha_2, \cdots, \alpha_r) \times \begin{bmatrix} 1 & \mu_1^1 & \cdots & \mu_1^{p-1} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & \mu_1^1 & \cdots & \mu_1^{p-1} \end{bmatrix} \quad (20)$$

式中: $e_{R(\gamma)}^*$ 为重构后第 γ 时刻的误差快照; $\mathbf{V}_{\text{and}}(p)$ 为用于重建的标准范德蒙德矩阵。

(4) 预测误差序列。

将反归一化的误差矩阵 $\mathbf{E}_R = [e_{R(1)} e_{R(2)} \cdots e_{R(p)}]$ 重构为式(21)中的 \mathbf{E}_{Rf} , 矩阵维度为 $g \times f$, $g = p - f + 1$, $e_{R(\gamma)}$ 为反归一化后第 γ 时刻的误差快照。

$$\mathbf{E}_{Rf} = \begin{bmatrix} e_{R(1)} & e_{R(2)} & \cdots & e_{R(f)} \\ e_{R(f+1)} & e_{R(f+2)} & \cdots & e_{R(2f)} \\ \vdots & \vdots & \ddots & \vdots \\ e_{R(g)} & e_{R(g+1)} & \cdots & e_{R(g+f-1)} \end{bmatrix} \quad (21)$$

对 \mathbf{E}_{Rf} 对角线进行平均运算,得到窗口长度为 f 的精确误差序列 \mathbf{E}_p 。其中,第 z 个元素的计算如下:

$$e_z = \begin{cases} \frac{1}{z+1} \sum_{q=1}^{z+1} e_{R(q, z-q+2)} & 1 \leq z < g-1 \\ \frac{1}{g} \sum_{q=1}^g e_{R(q, z-q+2)} & g-1 \leq z < f \\ \frac{1}{p-z} \sum_{q=z-f+2}^{p-f+1} e_{R(q, z-q+2)} & f \leq z < p \end{cases} \quad (22)$$

式中: q 、 z 为元素的位置信息。

根据式(22)更新的最终预测误差序列 \mathbf{e} 为:

$$\mathbf{e} = [e_1 \ e_2 \ \cdots \ e_f] \quad (23)$$

3 算例分析

文中所用数据为我国某地区 2019 年—2022 年的负荷历史运行数据与气温数据,共计有 11 类用户负荷,时间尺度均为 15 min。

3.1 聚类结果分析

(1) 一次聚类。11 个用户负荷原始数据经过数据预处理后,进行 k -means 聚类分析,结果见图 5,最佳聚类数 $k=4$ 。




图 5 k - S_c 曲线

Fig.5 The graph of k - S_c

(2) 二次聚类。将一次聚类结果与负荷特征、用户行为特征指标相结合进行二次聚类,得到结果如图6所示。




图6 基于SOM的二次聚类结果

Fig.6 SOM-based quadratic clustering results

由图6可知,二次聚类得到的聚类结果为3类,二次聚类将具有相似调节潜力的负荷聚为一类,使结果更有实际意义。

为方便后续的评估与预测,将各类负荷进行叠加,得到图7所示各类负荷用户单日负荷曲线。

文中根据各类负荷用户数据特征和对该地区生活生产模式的调研,将负荷用户分别定义为工业区负荷、居民区负荷和商业区负荷。工业负荷由于生产活动通常是连续的或按照固定的班次进行,负荷曲线比较平稳,峰谷变化相对较小,符合第1类曲线特征;居民负荷因居民活动的随机性特征变化而较为复杂,在居民活动时段负荷量较高,在凌晨后,负荷因居民入睡而处于低谷期,符合第2类曲线特征;商业负荷通常在工作日办公时间(09:00—17:00)有显著的高峰,在夜间和非工作时间明显下降,符合第3类曲线特征。

3.2 负荷调节潜力评估结果分析

将聚类后得到的3类用户负荷代入评估模型进行评估,评估结果如图8所示。

由图8可以看出,工业区负荷存在较大的可调节潜力,商业区次之,居民区最小。

工业负荷的调控主要是调整生产计划,控制机器的启停,所以具有一定的规律性,调节潜力也较为稳定,呈现周期性波动。

居民负荷可调节潜力很小,因为其用电模式相对分散且难以集中管理,并且要着重考虑用户的意愿以及电价,所以调节潜力主要集中在夜间。

商业负荷主要集中在白天,夜间只有少量安保负荷,因为要满足顾客的基本购物体验,所以调节潜力保持在比较稳定的区间,可调范围也较小。

所有负荷用户在00:00—06:00的电价优惠时




图7 各类负荷曲线

Fig.7 Load curve of various categories


段可下调潜力都较小,上调潜力较大;在08:00—17:00的用电高峰期,可上调潜力不多,可下调潜力较为突出,符合实际生产生活规律和用电需求;并且各类负荷在用电高峰期有较大的下调潜力,用电低谷期有较大的上调潜力,符合负荷调节需求。

3.3 负荷调节潜力预测结果分析


3.3.1 模型参数设置

将3.2节评估得到的两年数据集划分为训练集和测试集,比例为7:3。利用训练集对BiLSTM-DMD模型进行训练,确定模型参数。参数设置结果如表1所示。


为了验证所提方法的有效性,选取深度神经网络(deep neural network, DNN)和时间卷积网络(temporal convolutional network, TCN)进行对比。DNN的模型参数与BiLSTM类似,具体参数如表2所示。



(a) 工业区



(b) 居民区



(c) 商业区

图8 负荷调节潜力评估结果

Fig.8 Results of the load regulation potential assessment

表1 BiLSTM-DMD 模型参数

Table 1 BiLSTM-DMD model parameters

模型	参数名称	参数设置
BiLSTM模型	神经元数量	[128,64,32]
	学习率	0.000 1
	激活函数	ReLU
	正则化参数	0.000 1
	优化器	Adam
	批量大小	64
	训练轮次	100
DMD模型	滑动窗口的大小	[672,1 344]
	矩阵分解的秩	30
	收敛精度	10^{-7}
	矩阵分解方法	SVD

注: ReLU为修正线性单元,是一种常用的神经网络激活函数; SVD为奇异值分解。


表2 TCN 模型参数
Table 2 TCN model parameters

参数名称	参数设置	参数名称	参数设置
卷积核的数量	128	填充方式	same
卷积核的大小	5	初始化方法	glorot_uniform
扩张率	4	池化窗口的大小	2
激活函数	ReLU	输出层的节点数	1


3.3.2 BiLSTM 初步预测结果及误差

基于 BiLSTM 对工业区、居民区和商业区 3 大典型负荷用户进行初步预测,并得出预测值与实际值间误差,结果见图 9。

由图 9 可知,所提方法对波动复杂的工业用户调节潜力预测误差较大,预测值与真值误差在-10~5 MW 之间;商业区预测误差较小,在-3~1.5 MW 之间;居民区预测误差最小,在-2~0.5 MW 之间。



(a) 工业区



(b) 居民区




图9 BiLSTM 预测结果及误差

Fig.9 BiLSTM prediction results and errors

3.3.3 DMD 误差修正后的最终预测结果及误差

基于 DMD 对工业区、居民区和商业区 3 大典型负荷用户进行预测误差修正, 得出图 10 中的预测值与实际值误差结果。

从图 10 可以看出, 进行误差修正后, 预测精度能达到较理想的状态。工业区预测误差在-3.5~1.5 MW 之间; 商业区预测误差在-1.8~0.9 MW 之间; 居民区预测误差在-0.6~0.2 MW 之间。

3.3.4 模型预测结果对比

采取 MAPE 与 RMSE 作为衡量模型预测精度的评价标准, 文中所提方法与各类模型的评价指标对比数据如表 3 所示。

从表 3 可以看出, 关于 MAPE 指标, BiLSTM-DMD 方法比 BiLSTM 方法平均精度提高了 1.7%, 比 TCN、DNN 方法平均精度分别提高了 3.2% 和 3.3%。对于 RMSE 指标, BiLSTM-DMD 方法比 BiLSTM





图 10 BiLSTM-DMD 预测结果及误差

Fig.10 BiLSTM-DMD prediction results and errors

表 3 3 类典型用户负荷调节潜力预测误差对比


Table 3 Comparison of forecast errors for load regulation potential in three typical types of customers

方法	MAPE/%			RMSE/MW		
	工业区	居民区	商业区	工业区	居民区	商业区
BiLSTM-DMD	1.257	1.052	1.548	1.719	0.735	0.436
BiLSTM	4.256	1.872	2.895	4.085	2.454	2.144
TCN	5.885	2.654	5.021	9.252	3.339	2.237
DNN	6.051	3.571	4.036	10.732	4.571	2.121

方法平均精度提高了 1.9%, 比 TCN、DNN 方法平均精度分别提高了 4.0% 和 4.8%。因此, 文中所提的 BiLSTM-DMD 方法在精度上有显著提升。

4 结论

文中基于特征提取、指标量化、数据挖掘与构



建物理模型等技术,提出数据模型双驱动的负荷时序调节潜力评估及预测方法,以某地实际数据为例验证了所提方法的有效性与优越性。

(1)从自然环境、负荷特征、用户行为3个维度对调节潜力进行量化。采用 k -means和SOM结合的二次聚类模型,同时考虑各类负荷自身特征与调节特性,从而达到更好的聚类效果。在量化指标和负荷聚类的基础上,建立负荷调节潜力评估物理模型,实现对各类负荷全时刻上调及下调潜力评估,结果表明工业负荷调节潜力最大,商业负荷次之,居民负荷最小。

(2)为获得未来的负荷调节潜力趋势,提出将BiLSTM与DMD相结合的预测方法,与BiLSTM、TCN、DNN单一预测模型相比,所提方法预测误差更小,可为负荷可调潜力预测提供更可靠的数据参考。

(3)文中对负荷调节潜力的分析方法对于不同用户均具有适用性,可以有效分析用户在保障自身需求下参与电网削峰填谷的能力,为电网安全稳定和调度精益化提供数据支撑和决策参考。

参考文献:

- [1] 陈阳,谢丽蓉,马兰,等.考虑光伏预测误差兼顾平抑波动的双层储能运行策略[J].电力工程技术,2023,42(1):70-79.
CHEN Yang, XIE Lirong, MA Lan, et al. Double-layer energy storage operation strategy that takes into account PV output error and smooths out fluctuations[J]. Electric Power Engineering Technology, 2023, 42(1): 70-79.
- [2] 李晓庆,张培超,祝炜昊,等.基于灵敏度的光储直流配电网电压/网损自适应优化协调控制[J].电力建设,2024,45(7):88-99.
LI Xiaoqing, ZHANG Peichao, ZHU Weihao, et al. Sensitivity-based adaptive voltage/network loss-coordinated optimal control in photovoltaic-storage DC distribution systems[J]. Electric Power Construction, 2024, 45(7): 88-99.
- [3] 孙天贺,靳双源,刘国斌,等.考虑源荷不确定性的光伏小镇鲁棒优化配置[J].电力工程技术,2023,42(6):42-51.
SUN Tianhe, JIN Shuangyuan, LIU Guobin, et al. A robust optimization approach for capacity configuration of solar towns considering supply-demand uncertainties[J]. Electric Power Engineering Technology, 2023, 42(6): 42-51.
- [4] 成龙,李国庆,王翀,等.考虑预测误差不确定性和功率互济的配电网直流闭环重构[J].电力系统保护与控制,2024,52(24):97-108.
CHENG Long, LI Guoqing, WANG Chong, et al. DC loop-closed reconfiguration for distribution networks considering prediction error uncertainty and power complementarity[J]. Power System Protection and Control, 2024, 52(24): 97-108.
- [5] 廖家齐,于若英,刘瑜俊,等.基于自适应高斯混合模型的含高渗透率分布式光伏电力系统风险评估[J].电力系统保护与控制,2024,52(19):144-156.
LIAO Jiaqi, YU Ruoying, LIU Yujun, et al. Risk assessment of a power system with a high penetration of distributed photovoltaic based on self-adaptive Gaussian mixture model[J]. Power System Protection and Control, 2024, 52(19): 144-156.
- [6] 张光儒,马振祺,陈杰,等.考虑降压节能和光伏误差三维特性的主动配电网多时间尺度优化调度[J].电力建设,2024,45(8):159-172.
ZHANG Guangru, MA Zhenqi, CHEN Jie, et al. Multi-timescale scheduling method for active distribution network considering three-dimensional characteristics of PV prediction error and voltage regulation[J]. Electric Power Construction, 2024, 45(8): 159-172.
- [7] 温镇,唐昕,许金明,等.不同控制策略影响下光伏发电电能质量特性研究[J].水电能源科学,2015,33(11):202-206.
WEN Zhen, TANG Xin, XU Jinming, et al. Study on power quality characteristic for photovoltaic power generation under different control strategies[J]. Water Resources and Power, 2015, 33(11): 202-206.
- [8] OLIVEIRA J P, RODRIGUES A B, DA SILVA M G. Probabilistic evaluation of voltage control and reactive power techniques with photovoltaic distributed-generation[C]//2018 Simposio Brasileiro de Sistemas Eletricos (SBSE). Niteroi, Brazil. IEEE, 2018: 1-6.
- [9] 何娣.太阳能光伏并网发电系统的研究[D].西安:长安大学,2013.
HE Di. Research on photovoltaic grid-connected power generation system[D]. Xi'an: Changan University, 2013.
- [10] 欧奕昊,姜彤,张一航,等.考虑变流器无功调节特性的含高比例分布式光伏配电网电压控制方法[J].电力系统保护与控制,2024,52(20):105-118.
OU Yihao, JIANG Tong, ZHANG Yihang, et al. Voltage regulation method for a distribution network with high-penetration of distributed photovoltaic energy considering a converter's reactive power regulation characteristics[J]. Power System Protection and Control, 2024, 52(20): 105-118.
- [11] 王锋,宋惠宇,张欣欣.基于双碳目标的家庭错峰用电调度策略研究[J].电测与仪表,2024,61(12):212-218.
WANG Feng, SONG Huiyu, ZHANG Xinxin. Research on household off-peak electricity consumption scheduling strategy based on carbon peaking and carbon neutrality goals[J]. Electrical Measurement & Instrumentation, 2024, 61(12): 212-218.
- [12] 李经儒,潘峰,杨雨瑶,等.考虑源荷随机性与相关性的直流配电网量测概率优化配置方法[J].电测与仪表,2024,61(7):138-145.
LI Jingru, PAN Feng, YANG Yuyao, et al. Stochastic optimal placement method of measurement for DC distribution network considering probability and correlation of source load[J]. Elec-

- trical Measurement & Instrumentation, 2024, 61(7): 138-145.
- [13] 刘金朋, 杨昊, 吴澜, 等. 基于高斯混合模型的居民聚合响应潜力多重置信评估[J]. 电力工程技术, 2023, 42(2): 20-28.
LIU Jinpeng, YANG Hao, WU Lan, et al. Evaluation of residential demand response potential under multiple confidence scenarios based on Gaussian mixture model[J]. Electric Power Engineering Technology, 2023, 42(2): 20-28.
- [14] 孙厚涛. 含分布式电源的配电网多源协调控制策略研究[D]. 南京: 东南大学, 2016.
SUN Houtao. Research on distribution network multi-source coordinated control strategy with distributed generation interconnection[D]. Nanjing: Southeast University, 2016.
- [15] 文旭, 杨可, 毛锐, 等. 可调节负荷调控能力评估行业标准研究及应用[J]. 电网技术, 2021, 45(11): 4585-4594.
WEN Xu, YANG Ke, MAO Rui, et al. Research and application of industry standards for evaluation of adjustable load control capacity[J]. Power System Technology, 2021, 45(11): 4585-4594.
- [16] 朱天怡, 艾芊, 贺兴, 等. 基于数据驱动的用电行为分析及应用综述[J]. 电网技术, 2020, 44(9): 3497-3507.
ZHU Tianyi, AI Qian, HE Xing, et al. An overview of data-driven electricity consumption behavior analysis method and application[J]. Power System Technology, 2020, 44(9): 3497-3507.
- [17] 徐航. 综合能源系统中的综合需求响应策略研究[D]. 杭州: 浙江大学, 2019.
XU Hang. Research on integrated demand response strategy in integrated energy system[D]. Hangzhou: Zhejiang University, 2019.
- [18] 陈逸涵, 李扬, 沈运帷. 基于负荷控制潜力量化模型的工业用户群体画像方法[J]. 电力自动化设备, 2021, 41(8): 208-216.
CHEN Yihan, LI Yang, SHEN Yunwei. Industrial customer group portrait method based on potential quantization model of load control[J]. Electric Power Automation Equipment, 2021, 41(8): 208-216.
- [19] 祁江浩, 李凤婷, 张高航. 需求响应分段参与的多时间尺度源荷协调调度策略[J]. 电力系统保护与控制, 2021, 49(11): 61-69.
QI Jianghao, LI Fengting, ZHANG Gaohang. Multi-time scale scheduling strategy for source-load coordination considering demand response block participation[J]. Power System Protection and Control, 2021, 49(11): 61-69.
- [20] 徐青山, 丁一帆, 颜庆国, 等. 大用户负荷调控潜力及价值评估研究[J]. 中国电机工程学报, 2017, 37(23): 6791-6800, 7070.
XU Qingshan, DING Yifan, YAN Qingguo, et al. Research on evaluation of scheduling potentials and values on large consumers[J]. Proceedings of the CSEE, 2017, 37(23): 6791-6800, 7070.
- [21] TIAN C S, HAO Y, HU J M. A novel wind speed forecasting system based on hybrid data preprocessing and multi-objective optimization[J]. Applied Energy, 2018, 231: 301-319.
- [22] LI C, TAO Y, AO W G, et al. Improving forecasting accuracy of daily enterprise electricity consumption using a random forest based on ensemble empirical mode decomposition[J]. Energy, 2018, 165: 1220-1227.
- [23] 方娜, 陈浩, 邓心, 等. 基于VMD-ARIMA-DBN的短期电力负荷预测[J]. 电力系统及其自动化学报, 2023, 35(6): 59-65.
FANG Na, CHEN Hao, DENG Xin, et al. Short-term power load forecasting based on VMD-ARIMA-DBN[J]. Proceedings of the CSU-EPSC, 2023, 35(6): 59-65.
- [24] 周思思, 李勇, 郭钊秀, 等. 考虑时序特征提取与双重注意力融合的TCN超短期负荷预测[J]. 电力系统自动化, 2023, 47(18): 193-205.
ZHOU Sisi, LI Yong, GUO Yixiu, et al. Ultra-short-term load forecasting based on temporal convolutional network considering temporal feature extraction and dual attention fusion[J]. Automation of Electric Power Systems, 2023, 47(18): 193-205.
- [25] 王艳松, 申晓阳, 李强, 等. 基于PCA-GRD-LWR模型的海上油田中长期最大电力负荷预测[J]. 中国石油大学学报(自然科学版), 2023, 47(2): 129-135.
WANG Yansong, SHEN Xiaoyang, LI Qiang, et al. Forecasting of medium and long-term maximum power load for offshore oilfields based on PCA-GRD-LWR model[J]. Journal of China University of Petroleum (Edition of Natural Science), 2023, 47(2): 129-135.
- [26] 谭风雷, 徐刚, 李义峰, 等. 基于相似日和相似时刻的变压器顶层油温预测方法[J]. 电力工程技术, 2022, 41(2): 193-200.
TAN Fenglei, XU Gang, LI Yifeng, et al. A method of transformer top oil temperature forecasting based on similar day and similar hour[J]. Electric Power Engineering Technology, 2022, 41(2): 193-200.
- [27] CHE J X, WANG J Z, WANG G F. An adaptive fuzzy combination model based on self-organizing map and support vector regression for electric load forecasting[J]. Energy, 2012, 37(1): 657-664.
- [28] 臧海祥, 许瑞琦, 刘璟璇, 等. 基于多维融合特征和卷积神经网络的多任务用户短期负荷预测[J]. 电力系统自动化, 2023, 47(13): 69-77.
ZANG Haixiang, XU Ruiqi, LIU Jingxuan, et al. Short-term load forecasting for multi-task consumers based on multi-dimensional fusion feature and convolutional neural network[J]. Automation of Electric Power Systems, 2023, 47(13): 69-77.
- [29] 习伟, 蔡田田, 张镇, 等. 融合多元影响因素的配电台区BiLSTM负荷预测方法[J]. 天津大学学报(自然科学与工程技术版), 2023, 56(11): 1205-1216.
XI Wei, CAI Tiantian, ZHANG Zhen, et al. BiLSTM load forecasting method for transformer districts integrated with multiple influencing factors[J]. Journal of Tianjin University (Science and Technology), 2023, 56(11): 1205-1216.

[30] 王雷, 何坤, 李宗帅, 等. 基于 BiLSTM-Attention 的迁移学习变工况故障识别方法研究[J]. 电子测量与仪器学报, 2023, 37(7): 205-212.
WANG Lei, HE Kun, LI Zongshuai, et al. Transfer learning based on BiLSTM-Attention research on fault identification methods for variable operating conditions[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(7): 205-212.

[31] 李剑锋, 郝晓光, 杨春来, 等. 基于动态模式分解的新能源场站频率特性估计[J]. 电力系统及其自动化学报, 2023, 35(11): 107-113, 132.
LI Jianfeng, HAO Xiaoguang, YANG Chunlai, et al. Frequency characteristic estimation of new energy station based on dynamic mode decomposition[J]. Proceedings of the CSU-EPSA, 2023, 35(11): 107-113, 132.

[32] 李闯, 孔祥玉, 朱石剑, 等. 能源互联环境下考虑需求响应的

区域电网短期负荷预测[J]. 电力系统自动化, 2021, 45(1): 71-78.

LI Chuang, KONG Xiangyu, ZHU Shijian, et al. Short-term load forecasting of regional power grid considering demand response in energy interconnection environment[J]. Automation of Electric Power Systems, 2021, 45(1): 71-78.

作者简介:



赵艳

赵艳(2001), 女, 硕士在读, 研究方向为电力系统自动化(E-mail: 983554250@qq.com);

柳伟(1985), 男, 博士, 副教授, 博士生导师, 通信作者, 研究方向为新型配电系统运行控制、实时仿真及人工智能应用;

唐鹏程(1997), 男, 硕士, 研究方向为电力系统自动化。

Data-driven and model-driven evaluation and prediction methods for load regulation potential

ZHAO Yan, LIU Wei, TANG Pengcheng, SONG Lijuan, ZHAO Yilin, YU Xuechang
(School of Automation, Nanjing University of Science and Technology, Nanjing 210094, China)

Abstract: In the context of high penetration of photovoltaics in distribution networks, researching the load regulation potential is crucial for grid safety and refined dispatching. Thus, a data-driven and model-driven evaluation and prediction method for load regulation potential is proposed. Firstly, a multi-dimensional evaluation index system and assessment model for load regulation potential are constructed. A two-step clustering method, including k-means for load feature extraction and self-organizing map (SOM) for regulation potential feature fusion, is introduced. This enables the assessment of the temporal up-regulation and down-regulation potential of various loads. Secondly, an intelligent prediction method that integrates bidirectional long short-term memory (BiLSTM) and dynamic mode decomposition (DMD) is proposed to predict the 15-minute level load regulation potential for the next day. Finally, simulation verification of the proposed strategy is conducted using local load data. The evaluation results confirm the effectiveness of the proposed assessment and prediction methods, demonstrating that the BiLSTM-DMD model can achieve high prediction accuracy.

Keywords: data-driven and model-driven; load regulation potential; potential assessment; intelligent prediction; secondary clustering; neural networks

(编辑 陈雯嘉)