



面向虚拟电厂运营的温度敏感负荷分析与演变趋势研判

周颖¹, 白雪峰², 王阳³, 邱敏¹, 孙冲⁴, 武亚杰¹, 李彬²

(1. 需求侧多能互补优化与供需互动技术北京市重点实验室(中国电力科学研究院有限公司), 北京 100192;
2. 华北电力大学 电气与电子工程学院, 北京 102206; 3. 国家电网有限公司, 北京 100031;
4. 国网河北省电力有限公司 营销服务中心, 河北石家庄 050081)

摘 要: 随着极端天气频发, 温度敏感负荷用电逐年攀升, 温度敏感负荷作为虚拟电厂优质的调控资源, 亟须分析气象变化对于此类负荷的影响, 由于叠加极端高温、大规模寒潮等异常天气的影响, 温度敏感负荷波动剧烈, 常规分析预测方法难以适应极端气象场景。针对寒潮天气下温度敏感负荷样本数据及预测精度不足的问题, 提出寒潮天气小样本条件下的温度敏感负荷日最大负荷预测方法。该方法先采用时序对抗生成网络(TimeGAN)扩充寒潮期间小样本数据, 再采用卷积-长短时记忆神经网络(CNN-LSTM)对寒潮期间的日最大负荷进行预测。以国内某省近两年迎峰度冬期间数据进行模型验证, 结果表明所提模型优于其他模型的预测结果, 在验证集上日最大负荷的预测精度为 99.5%。

关键词: 温度敏感负荷预测; 寒潮; 时间序列生成对抗网络; 虚拟电厂; 卷积神经网络; 长短时记忆神经网络

DOI: 10.11930/j.issn.1004-9649.202307100

0 引言

随着人们对生产生活舒适度要求的提高, 同时由于极端天气频发、广发, 使得温度敏感负荷不断攀升, 负荷峰值不断刷新纪录^[1], 电力保供压力逐渐增加。2022 年 11 月国家能源局发布《电力现货市场基本规则(征求意见稿)》要求推动虚拟电厂等新兴市场主体参与电力现货交易, 充分激发和释放用户侧灵活调节能力。国家能源局 2023 年 3 月发布的《关于加快推进能源数字化智能化发展的若干意见》强调要进一步提高负荷预测精度。上海的密集商业楼宇虚拟电厂中温度敏感负荷占比较大^[2], 准确的温度敏感负荷预测为虚拟电厂制定需求响应方案、参与电力市场交易提供必要的参考依据, 尤其是在迎峰度夏/度冬期

间的极端高温、寒潮时, 是进行虚拟电厂调峰的重要场景, 但目前对于极端气象场景的预测精度往往较低, 准确把握温度敏感负荷大小能够帮助虚拟电厂在发电侧综合评估区域内分类分布式发电机组的攀峰响应能力, 在用电侧可以及时下达需求响应邀约以降低部分负荷^[3], 缓解紧张的供需形势。

目前温度敏感负荷测算方法主要有“基线法”与“空调装接容量推算法”^[4]。“基线法”即夏季或冬季日用电负荷曲线剔除对应的基础负荷^[5], 但在春秋季典型日的选取规则、典型日中异常日的剔除方法上略有不同^[6-7]。“空调装机容量推算法”考虑各行业空调装机容量大小、同时率等因素对区域温度敏感负荷进行推算, 但是需要大量走访调查, 工作量较大, 在实际中难以应用。短期温度敏感负荷主要受地区气象因素、经济因素、生活习惯等影响, 其中气象因素中温度对负荷影响最大^[8]。温度敏感负荷预测主要分为两大类: 一是传统回归预测, 包括多元线性回归预测、多元非线性回归预测、差分整合移动平均自回归模型(autoressive integrated moving

收稿日期: 2023-07-26; **修回日期:** 2023-11-14。

基金项目: 国家电网有限公司科技项目(支撑重过载台区治理的区域供用电综合预测与智能预警技术研究与应用, 5108-202218280A-2-379-XG)。



average model, ARIMA) 预测等^[9-14], 这类模型数学机理清晰并且考虑了负荷数据的时序性, 类似于 ARIMA 的时间序列模型对波动性较小的数据预测效果好, 但是寒潮来临时, 气象以及负荷变化波动较大, 会出现较大误差; 二是基于机器学习、深度学习等人工智能预测, 采用逻辑回归、神经网络等模型找出数据的周期规律实现预测^[15-16], 这类方法往往需要较大的数据量, 但是寒潮天气的数据样本较少, 训练样本不足, 因此需要研究小样本条件下的负荷预测方法^[17]。本文为支撑虚拟电厂运营, 精准预测虚拟电厂在寒潮天气下的负荷大小, 通过对负荷的分解, 提取出温度敏感负荷, 提高气象因素与负荷的相关性, 并采用改进的时间序列生成对抗网络, 扩充寒潮期间温度敏感负荷数据, 增加样本训练量, 最后采用卷积-长短时记忆神经网络对寒潮期间的日最大负荷进行预测。

1 温度敏感负荷分解与影响因素分析

1.1 温度敏感负荷分解方法

温度敏感负荷采用“基线法”, 将区域秋季平均温度处于 20 ℃ 左右, 未发生大规模降雨和其他异常天气以及非法定节假日作为典型日选取范围, 并在此范围内选取负荷较为平缓的周期, 设定为典型日。基于典型日负荷每日 96 点数据, 将典型日按各类型日 (指自然周周一到周日) 进行分配, 并做平均计算, 最终得到每个类型日共 7 条基线 $P_{\text{base},k}$ 。

$$P_{\text{base},k} = \left(\sum_{n=1}^N P_{\text{act},i,n} \right) / N \quad (1)$$

式中: $P_{\text{base},k}$ 为第 k 类典型日基线负荷 ($k=1, 2, \dots, 7$); $P_{\text{act},i,n}$ 为秋季第 n 周第 i 天负荷 ($n=1, 2, \dots, N, i=1, 2, \dots, 7$); N 为秋季总周数。

此外, 为确保得到的基线负荷更具有科学性、严谨性、普遍性, 需要尽可能拓宽典型日的选取周期, 以保证各类型日基线负荷均由 3~5 个典型日计算得出。

温度敏感负荷 $P_{\text{tem},m}$ 可表示为

$$P_{\text{tem},m} = P_m - P_{\text{base},k} \quad (2)$$

式中: P_m 为度冬期间第 m 天实际负荷。

1.2 影响负荷的气象因素选取

为分析多种气象因素对于负荷的影响程度, 本文采用皮尔逊相关系数法将负荷数据序列 (P) 与气象因素序列 ($X_1, X_2, \dots, X_J$) 进行分析, 其相关系数 r_j 计算公式为

$$r_j = \frac{\sum_{\gamma=1}^q (X_{j,\gamma} - \bar{X}_j)(P_\gamma - \bar{P})}{\sqrt{\sum_{\gamma=1}^q (X_{j,\gamma} - \bar{X}_j)^2} \sqrt{\sum_{\gamma=1}^q (P_\gamma - \bar{P})^2}}, j \in [1, J] \quad (3)$$

式中: P_γ 为负荷序列的第 γ 个数据; X_j 为第 j 个气象因素序列; $X_{j,\gamma}$ 为序列 X_j 的第 γ 个数据; q 为序列长度。

相关系数 r_j 越大, 表明该气象因素对负荷的影响越大。人们的感受取决于多个气象因素的综合影响, 而单一的气象指标往往无法准确地衡量人体的实际感觉, 本文采用体感温度、寒湿指数、人体舒适度等综合气象指标构建预测模型。

1) 体感温度

体感温度^[18] (A_T) 即人体感官对外界环境的身体或精神感受, 受气温、风速、空气湿度等多重因素影响^[19], 其计算公式为

$$\begin{cases} A_T = 1.07T + 0.2e - 0.65v - 2.7 \\ e = \frac{R_H}{100} \times 6.105 \times \exp \frac{17.27T}{237.7 + T} \end{cases} \quad (4)$$

式中: T 为气温, ℃; R_H 为相对湿度, %; v 为风速, m/s; e 为水汽压, hPa。

2) 人体舒适度

人体舒适度^[20] (K) 是指不同气候环境下人体舒适感从气象角度的评价, 类似于体感温度, 其计算公式为

$$K = 1.8T - 0.55(1.8T - 26)(1 - R_H) - 3.2\sqrt{v} + 3.2 \quad (5)$$

3) 寒湿指数

寒湿指数^[21] (E_e) 是考虑到中国南方冬季受大陆季风气候的影响, 湿度较大, 即使气温处于高位, 仍给人一种阴冷的感觉, 即所谓的湿寒。其计算公式为

$$E_e = (33 - T)(3.3\sqrt{v} - v/3 + 20)\exp(0.005|R_H - 40\%|) \quad (6)$$

1.3 日类型处理

每日负荷与日类型变化也有关系, 通常情况

下，工作日的负荷通常大于休息日负荷，一周内最大负荷往往发生在星期三或星期四。负荷存在一定周期性，本文在预测时将考虑日类型的影响，为使日类型特征间的距离计算更加合理，将一周七天分别进行独热编码（one-hot encoding）[22]。

2 极端天气小样本条件下负荷短期预测

2.1 基于 TimeGAN 的寒潮负荷、气象数据扩充

根据寒潮天气标准[23]，大多数区域全年一般发生 2~4 次寒潮，属于小样本事件，神经网络在小样本预测中精度往往较低。因此，先要根据寒潮数据特性，生成相关负荷、气象数据。在数据生成领域，生成对抗网络（generative adversarial networks, GAN）常用于图像识别，在音频、电力负荷这类序列数据上的应用可以看作是这些方法的扩展[24-25]。该算法通过生成器与判别器的博弈，从随机分布的数据逐渐学习真实样本数据的特征分布，使得判别器最终无法区分生成对抗网络输出生成样本与输入的真实样本。TimeGAN（time-series generative adversarial networks）是在 GAN 的基础上，结合自回归模型，不仅可以模拟初始数据的分布，还能保留数据的动态时序相依特性[26]。TimeGAN 通过滑动窗口的方式，可将二维时间序列，切片为一系列的三维样本空间。TimeGAN 由嵌入函数、恢复函数、序列生成器和序列鉴别器组成，前 2 个组件组成自编码器，后 2 个组成对抗网络，如图 1 a) 所示。时序数据有静态特征与动态特征之分，前者不会因为时间而改变的特征，例如用户身份信息；后者随着时间而改变，例如体温、血压、气温等[24]。考虑到负荷与气象数据均为动态特征，本文将损失优化函数中的静态特性相关项去除，得到改进的 TimeGAN，如图 1 b) 所示。实线表示对应函数计算，虚线表示重复计算过程，橙色线表示损失计算，其神经网络学习过程为

$$L_R = E_{X_{1:T-p}} \left[\sum_t \|x_t - \tilde{x}_t\|_2 \right] \quad (7)$$

式中： L_R 为自编码器的损失值，需优化至满足约束的最小值； $E[\cdot]$ 表示向量间的欧式距离，用于计算原始样本与生成样本的距离； p 为原始样本




图 1 TimeGAN 架构及本文改进的 TimeGAN 架构

Fig. 1 The TimeGAN architecture and the improved TimeGAN architecture in this paper

的时序条件分布； x_t 为实际的时序数据； $\tilde{x}_t$ 为随机数据通过自编码器学习得到的时序数据。

样本时序依赖关系的学习过程为

$$\begin{cases} L_S = E_{X_{1:T-p}} \left[\sum_t \|h_t - g_x(h_{t-1}, z_t)\|_2 \right] \\ h_t = e_x(h_{t-1}, x_t) \end{cases} \quad (8)$$

式中： L_S 是监督损失函数，也需要对其优化令其尽可能小； h_t 为映射在潜在空间的隐藏层向量； e_x 为递归计算的嵌入函数； g_x 表示学习时序特征的循环网络； z_t 表示高斯分布的随机向量。

对抗网络参数优化过程为



$$L_U = E_{X_{1:T-p}} \left[\sum_t \log y_t \right] + E_{X_{1:T-\hat{p}}} \left[\sum_t \log(1 - \hat{y}_t) \right] \quad (9)$$

式中： L_U 为无监督损失函数； y_t 为判别器对真实样本的分类； $\hat{y}_t$ 为判别器对合成样本的分类； $\hat{p}$ 为合成样本的时序条件分布。

自编码器的参数优化过程为

$$\min_{\theta_e, \theta_r} (\lambda L_S + L_R) \quad (10)$$

对抗生成网络中参数的优化过程为

$$\min_{\theta_g} (\eta L_S + \max_{\theta_d} L_U) \quad (11)$$

式中： θ_e 、 θ_r 、 θ_g 和 θ_d 分别为嵌入函数、恢复函数、序列生成器和序列判别器中的参数； η 和 λ 为平衡对抗网络和自编码器中损失函数的超参数， η 和 λ 取值大于0，TimeGAN对这2个超参数并不敏感^[24]，本文算例中 $\eta=10$ 、 $\lambda=1$ 。

2.2 基于CNN-LSTM的负荷预测模型

2.2.1 卷积神经网络（CNN）

卷积神经网络（convolutional neural network, CNN）是一种深度学习模型，CNN因其具有高效的特征提取能力，在电网故障智能识别^[27]、非侵入检测^[28]等领域已有大量应用。卷积层和池化层是CNN的核心组成部分。卷积层通过共享权重和局部连接的方式，可对电力负荷数据进行有效的非线性局部特征提取，而池化层则扮演着降低特征维度的角色，以生成更为关键的特征信息，提高模型的鲁棒性和泛化能力。

2.2.2 长短期记忆神经网络（LSTM）

相较于循环神经网络（recurrent neural network, RNN），LSTM通过引入遗忘门、输入门和输出门的逻辑控制单元进行网络中神经元的状态保持与更新，自动调整信息的流动，避免信息的丢失或重叠^[29]。LSTM架构中，输入门 i_t 用于控制有多少新信息可以进入LSTM单元；遗忘门 f_t 用于控制前一个记忆单元的输出是否传递到当前时刻的记忆单元中；输出门 o_t 控制记忆单元的输出状态，通过输出门，LSTM可以有选择地输出记忆单元中的信息，灵活地提供给后续的层或模型使用。LSTM通过学习负荷及气象数据的时间相关性，加快网络收敛速度，有助于提高短期电力负荷预测精度。LSTM网络计算步骤如式（12）所示。

$$\begin{cases} i_t = \sigma(W_i x_t + U_i g_{t-1} + b_i) \\ f_t = \sigma(W_f x_t + U_f g_{t-1} + b_f) \\ o_t = \sigma(W_o x_t + U_o g_{t-1} + b_o) \\ \tilde{c}_t = \tanh(W_c x_t + U_c g_{t-1} + b_c) \\ c_t = i_t \circ \tilde{c}_t + f_t \circ c_{t-1} \\ g_t = o_t \circ \tanh(c_t) \end{cases} \quad (12)$$

式中：输入门 i_t 由输入 x_t 、前一时刻的隐藏层输出 g_{t-1} 和激活函数 σ 共同决定，通过激活函数输出一个介于0和1之间的值； W_i 、 U_i 和 b_i ， W_f 、 U_f 和 b_f ， W_o 、 U_o 和 b_o 分别为输入门、遗忘门、输出门的训练参数； $\tanh$ 为激活函数。

2.2.3 TimeGAN-CNN-LSTM 模型结构

本文所设计的TimeGAN-CNN-LSTM结构如图2所示。首先，数据经过关键特征筛选后，进入TimeGAN进行寒潮数据扩充，随后通过包含1层卷积层的卷积神经网络（CNN）进行特征提取，每层包含 3×3 个卷积核，步长为2。接着，使用1层池化层对数据进行筛选，并使用1层Flatten层将数据扁平化。经过筛选和处理后的数据输入包含1层LSTM网络层的LSTM网络中进行模型构建和训练。在LSTM层中，本文设置了20个神经元，滑动窗口大小设为7。使用全连接层对数据特征进行增强，并将增强后的结果输出。为了调节模型参数，选择均方根误差作为损失函数，并结合Adam优化器使用验证集数据进行优化，更好地调整模型参数，以提高模型的准确性和性能。




图 2 TimeGAN-CNN-LSTM 模型流程示意
Fig. 2 The TimeGAN-CNN-LSTM model flowchart

3 算例分析

本文采用的数据为2021-11-15—2022-02-15与2022年12月某省的负荷数据和气象数据（来自气象网站），气象指标采用地市每日用电



量的加权平均，合成该省气象指标，具体步骤为：将各地市售电量与全省售电量的占比作为权重，对各地市的每日气象数据求加权平均，以省日最低气温 $T_{\min}$ 为例，可表示为

$$T_{\min} = \sum_{\varphi=1}^d \left(\frac{E_{C,\varphi}}{E_p} T_{EM,\varphi} \right) \quad (13)$$

式中： $E_{C,\varphi}$ 为第 φ 个地市级公司售电量； E_p 为省公司售电量； $T_{EM,\varphi}$ 为第 φ 个地市级公司所在地的最低温度； d 为该省的地市级公司个数。

气象数据时间颗粒度为一日一点。将数据集划分为训练集、验证集、测试集，其中以小样本扩充的数据与 2021-11-15—2022-01-15 数据作为训练集、2022-01-16—2022-02-15 数据作为验证集、以 2022-12-13—12-20 该省寒潮期间的数据作为测试集。本文模型的训练及验证均在 TensorFlow2.0 深度学习框架实现。

为了验证本文所提算法的有效性，分别计算总负荷、基础负荷以及温度敏感负荷与各气象指标的相关系数。各因素与日最大负荷的相关性如表 1 所示。

表 1 各气象指标与不同负荷相关系数
Table 1 The correlation coefficient between meteorological factors and different loads

项目	相关系数		
	总负荷	温度敏感负荷	基础负荷
最高温度	-0.69	-0.74	-0.34
平均温度	-0.72	-0.77	-0.20
最低温度	-0.70	-0.74	-0.32
风速	-0.44	-0.23	0.17
湿度	0.15	0.20	-0.16
寒湿指数	0.70	0.67	0.35
体感温度	-0.75	-0.78	-0.28
人体舒适度	-0.74	-0.77	-0.34

由表 1 可知，通过负荷分解得到的温度敏感负荷与气象的相关性较总负荷与气象的相关性普遍升高，因此，本文选择与负荷相关性最大的 2 种二次气象指标（体感温度、人体舒适度）以及平均温度作为预测模型气象输入参数。

3.1 生成数据分析

本文通过 Q-Q 图检验生成数据和原始数据

是否满足同一分布，若图中的散点分布在对角线的周围，表示生成数据和原始数据的分布接近，同时根据对生成数据和原始数据的分布数据进行高斯函数拟合，可直观看到分布差异。

本文对 2021-11-15—2022-02-15 数据中满足寒潮条件的样本进行筛选，得到 4 轮寒潮数据，每轮寒潮大概影响 5~7 天的负荷，因此得到寒潮样本数据为 23 天，每天数据包括日敏感负荷、平均温度、体感温度、人体舒适度、独热编码的日类型数据。采用 TimeGAN 算法对各类数据扩充至 552 组，图 3、图 4 为平均温度、用电负荷的 Q-Q 图和真实值与生成值的概率分布情况。原始数据与生成数据的分布大致相同，说明 TimeGAN 算法成功地对气象特征和温度敏感负荷特征进行了学习，并生成带有真实样本特征的新样本。




图 3 平均温度的合成样本与真实样本分布情况
Fig. 3 Distribution of synthetic and real samples of average temperature

3.2 预测精度分析

为验证预测精度，本文采用平均绝对百分比误差 (E_{MAP})、平均绝对误差 (E_{MA}) 作为评价指标，相关公式为

$$E_{MAP} = \frac{1}{s} \sum_{\delta=1}^s \left| \frac{p_{\delta} - \tilde{p}_{\delta}}{p_{\delta}} \right| \times 100\% \quad (14)$$

$$E_{MA} = \frac{1}{s} \sum_{\delta=1}^s |p_{\delta} - \tilde{p}_{\delta}| \quad (15)$$

式中： s 为样本数目； p_{δ} 为第 δ 个样本的真实电力




图 4 负荷的合成样本与真实样本分布情况

Fig. 4 Distribution of synthetic and real samples of load

负荷值； $\hat{p}_\delta$ 为第 δ 个样本的预测电力负荷值。

为进一步说明本文模型在寒潮期间负荷预测中的优势，对 2022 年 12 月中旬的一次寒潮期间的负荷进行预测。图 5 是采用不同预测算法直接对总负荷进行预测的对比结果，图 6 是温度敏感负荷+基础负荷的预测结果，同时为了证明本文所提算法有效性，将本文模型与目前常用方法对比。各模型在训练集上的误差对比如表 2 所示。




图 5 不同算法对总负荷的预测结果

Fig. 5 The prediction results of each algorithm for total load direct prediction

预测结果表明，通过将总负荷分解为温度敏感负荷与基础负荷，可提高各类算法对于总负荷的预测精度，5 种预测模型的平均绝对误差平均




图 6 对各算法温度敏感负荷预测值+基础负荷的预测结果

Fig. 6 The prediction results of each algorithm with the predicted value of temperature sensitive load + basic load

表 2 误差分析

Table 2 Error analysis

模型方法	直接预测总负荷		预测温度敏感负荷+基础负荷	
	$E_{MA}/(\text{万kW})$	$E_{MAP}/\%$	$E_{MA}/(\text{万kW})$	$E_{MAP}/\%$
多元线性回归	86.11	0.99	82.68	0.96
BP神经网络	158.88	1.82	150.06	1.74
LSTM	171.19	1.95	78.20	0.91
CNN-LSTM	159.60	1.83	75.10	0.86
TimeGAN-CNN-LSTM	51.20	0.59	39.98	0.46

降低了 27.70%，百分比误差平均降低了 27.13%，验证了负荷分解在提高短期预测精度上的有效性；在数据扩充之前，其他算法由于寒潮样本不足，对于寒潮期间负荷的攀升速度预测过低，本文所提算法在寒潮期间平均绝对误差仅为 39.98 万 kW，平均绝对百分比误差为 0.46%。

4 结论

本文基于多类型气象指标，提出一种基于负荷分解及小样本生成的 CNN-LSTM 网络模型，以中国某省数据进行模型训练。得到以下结论。

1) 采用负荷分解得到的温度敏感负荷与体感温度、人体舒适度等二次气象指标的相关性普遍大于总负荷与此类指标的相关性，并高于与单一气象的相关性。通过负荷分解与二次气象指标，选择与温度敏感负荷相关性较高的指标，可进一步提升温度敏感负荷的预测精度。



2) 采用 TimeGAN 算法对学习寒潮期间的负荷及气象数据的时序特征，并对样本进行扩充，从生成数据与原始数据的概率分布和实际预测精确度效果可知，生成数据在保留原始数据分布特征的基础上，弥补了寒潮期间负荷样本过少、预测模型难以学习其时序特征的不足。

3) 本文选用的基于 CNN-LSTM 预测模型在输入多维特征参数下可以充分考虑温度敏感负荷的时序特性，提高对历史负荷、气象参数的利用率，提高在短期电力负荷预测中的预测精度，有利于虚拟电厂提前安排运营计划。

4) 未来随着极端天气的频发，温度敏感负荷占比逐年升高，将愈发成为虚拟电厂中重要的调控资源，可在负荷预测的基础上，进一步研究极端天气下温度敏感负荷可调节潜力，支撑虚拟电厂调控资源的挖掘。

参考文献：

- [1] 辛保安: 2022 年国家电网全年电网投资超 5000 亿元 [EB/OL]. (2023-01-12) [2023-03-12]. <http://hn.people.com.cn/GB/n2/2023/0112/c356884-40263848.html>.
- [2] 赵建立, 向佳霓, 汤卓凡, 等. 虚拟电厂在上海的实践探索与前景分析 [J]. 中国电力, 2023, 56(2): 1–13.
ZHAO Jianli, XIANG Jiani, TANG Zhuofan, *et al.* Practice exploration and prospect analysis of virtual power plant in Shanghai[J]. Electric Power, 2023, 56(2): 1–13.
- [3] 康重庆, 陈启鑫, 苏剑, 等. 新型电力系统规模化灵活资源虚拟电厂科学问题与研究框架 [J]. 电力系统自动化, 2022, 46(18): 3–14.
KANG Chongqing, CHEN Qixin, SU Jian, *et al.* Scientific problems and research framework of virtual power plant with enormous flexible distributed energy resources in new power system[J]. Automation of Electric Power Systems, 2022, 46(18): 3–14.
- [4] 谢敏, 邓佳梁, 刘明波, 等. 基于气象信息和熵权理论的降温负荷估算方法 [J]. 电力系统自动化, 2016, 40(3): 135–139.
XIE Min, DENG Jialiang, LIU Mingbo, *et al.* Temperature-lowering load estimation method based on meteorological data and entropy weight theory[J]. Automation of Electric Power Systems, 2016, 40(3): 135–139.
- [5] 殷跃. 重庆电网夏季高峰负荷特性分析及优化措施 [J]. 宁夏电力, 2021(5): 28–33, 43.
YIN Yue. Characteristic analysis of summer peak load and optimization measures in Chongqing power grid[J]. Ningxia Electric Power, 2021(5): 28–33, 43.
- [6] 史静, 周琪, 谈健, 等. 江苏电网夏季空调负荷特性挖掘与温度敏感性辨识 [J]. 电力工程技术, 2018, 37(3): 28–32.
SHI Jing, ZHOU Qi, TAN Jian, *et al.* The load excavation and temperature sensitivity identification of air conditioning in summer of Jiangsu power grid[J]. Electric Power Engineering Technology, 2018, 37(3): 28–32.
- [7] 袁斌. 陕西电网夏季降温负荷与温度相关性研究 [J]. 电网与清洁能源, 2020, 36(6): 19–24, 30
YUAN Bin. Correlation analysis of cooling load and temperature in Shaanxi power grid in summer[J]. Power System and Clean Energy, 2020, 36(6): 19–24, 30
- [8] 郭占伍, 张泽亚, 周兴华, 等. 考虑气象因素的电采暖负荷预测研究 [J]. 电测与仪表, 2022, 59(2): 154–158
GUO Zhanwu, ZHANG Zeya, ZHOU Xinghua, *et al.* Study on forecasting method of electric heating load considering meteorological factors[J]. Electrical Measurement & Instrumentation, 2022, 59(2): 154–158
- [9] 张航, 杨靖, 李昊霖. 基于改进回归模型的电网降温负荷预测 [J]. 控制工程, 2023, 30(3): 513–519.
ZHANG Hang, YANG Jing, LI Haolin. Power grid cooling load forecast based on improved regression model[J]. Control Engineering of China, 2023, 30(3): 513–519.
- [10] 金丽莉, 谭风雷, 吴志坚, 等. 考虑积温效应的负荷预测研究 [J]. 电力需求侧管理, 2013, 15(1): 7–10, 14.
JIN Lili, TAN Fenglei, WU Zhijian, *et al.* The study of load forecasting accounting accumulated temperature effect[J]. Power Demand Side Management, 2013, 15(1): 7–10, 14.
- [11] 董莉娜, 张志劲, 王茂政. 基于历史天气的区域电网负荷预测的研究 [J/OL]. 中国测试: 1–7[2023-06-16]. <https://kns.cnki.net/kcms/detail/51.1714.TB.20210722.0952.002.html>.
DONG Lina, ZHANG Zhijin, WANG Maozheng. Research on regional power grid load forecasting based on historical weather[J/OL]. China Measurement & Test: 1–7[2023-06-16]. <https://kns.cnki.net/kcms/detail/51.1714.TB.20210722.0952.002.html>.
- [12] 苏振宇, 龙勇, 赵丽艳. 基于 regARIMA 模型的月度负荷预测效果研究 [J]. 中国电力, 2018, 51(5): 166–171.
SU Zhenyu, LONG Yong, ZHAO Liyan. Study on the monthly power load forecasting performance based on regARIMA model[J]. Electric Power, 2018, 51(5): 166–171.
- [13] 成丹, 刘静, 郭淳薇, 等. 基于积温效应的华中电网电力负荷预



- 测[J]. 气象科技, 2018, 46(4): 814–821.
- CHENG Dan, LIU Jing, GUO Chunwei, *et al.* Prediction of electric loads over central China based on accumulated temperature effect[J]. *Meteorological Science and Technology*, 2018, 46(4): 814–821.
- [14] 李晨熙. 基于 ARIMA 模型的短期电力负荷预测[J]. 吉林电力, 2015, 43(6): 22–24.
- LI Chenxi. A short-term load forecasting model based on ARIMA[J]. *Jilin Electric Power*, 2015, 43(6): 22–24.
- [15] 李明节, 梁志峰, 许涛, 等. 基于敏感气温空间分布的度夏度冬最大负荷预测与应用研究[J]. 电网技术, 2023, 47(3): 1088–1098.
- LI Mingjie, LIANG Zhifeng, XU Tao, *et al.* Prediction and application of maximum daily load in summer and winter based on spatial distribution of sensitive temperatures[J]. *Power System Technology*, 2023, 47(3): 1088–1098.
- [16] CIECHULSKI T, OSOWSKI S. High precision LSTM model for short-time load forecasting in power systems[J]. *Energies*, 2021, 14(11): 2983.
- [17] 贾巍, 黄裕春. 基于小样本数据差分扩容的微电网负荷预测方法[J]. 中国电力, 2023, 56(8): 151–156, 165.
- JIA Wei, HUANG Yuchun. Method of load forecasting in microgrid based on differential expansion of small sample data[J]. *Electric Power*, 2023, 56(8): 151–156, 165.
- [18] STEADMAN R G. A universal scale of apparent temperature[J]. *Journal of Climate and Applied Meteorology*, 1984, 23(12): 1674–1687.
- [19] 王汶, 彭爱珏, 张佳丽, 等. 基于体感温度的中国供暖需求分区[J]. 长江流域资源与环境, 2019, 28(1): 12–20.
- WANG Wen, PENG Aijun, ZHANG Jiali, *et al.* Heating demand zoning in China based on apparent temperature[J]. *Resources and Environment in the Yangtze Basin*, 2019, 28(1): 12–20.
- [20] 王惠中, 刘轲, 周佳. 基于综合气象指数和日期类型的电力系统负荷预测[J]. 电网与清洁能源, 2015, 31(9): 67–71.
- WANG Huizhong, LIU Ke, ZHOU Jia. Power system load forecasting based on comprehensive meteorological index and date type[J]. *Power System and Clean Energy*, 2015, 31(9): 67–71.
- [21] 黄佳. 全天候电网特殊日短期负荷预测建模[D]. 南宁: 广西大学, 2017.
- HUANG Jia. Modeling of power system short-term load forecasting for special day in all-weather[D]. Nanning: Guangxi University, 2017.
- [22] 许飞. 基于机器学习的短期负荷预测[D]. 广州: 华南理工大学, 2020.
- XU Fei. Short-term load forecasting based on machine learning[D]. Guangzhou: South China University of Technology, 2020.
- [23] 中国气象局: 寒潮定义和标准[EB/OL]. (2018-11-19) [2023-03-19]. https://www.cma.gov.cn/2011xzt/kpbd/ColdWave/2018050901/201811/t20181119_483585.html.
- [24] YOON J, JARRETT D, SCHAAR M. Time-series generative adversarial networks[C]// *Neural Information Processing Systems (NeurIPS)*. 2019.
- [25] 林珊, 王红, 齐林海, 等. 基于条件生成对抗网络的短期负荷预测[J]. 电力系统自动化, 2021, 45(11): 52–60.
- LIN Shan, WANG Hong, QI Linhai, *et al.* Short-term load forecasting based on conditional generative adversarial network[J]. *Automation of Electric Power Systems*, 2021, 45(11): 52–60.
- [26] 叶林, 李奕霖, 裴铭, 等. 寒潮天气小样本条件下的短期风电功率组合预测[J]. 中国电机工程学报, 2023, 43(2): 543–555.
- YE Lin, LI Yilin, PEI Ming, *et al.* Combined approach for short-term wind power forecasting under cold weather with small sample[J]. *Proceedings of the CSEE*, 2023, 43(2): 543–555.
- [27] 郭威, 史运涛. 基于空间域图像生成和混合卷积神经网络的配电网故障选线方法[J/OL]. 电网技术: 1–14[2023-03-22]. <http://kns.cnki.net/kcms/detail/11.2410.tm.20230310.1705.003.html>.
- Guo Wei, Shi Yuntao. A Fault Line Selection Method for Distribution Network Based on Spatial Domain Image Generation and Hybrid Convolutional Neural Network [J/OL]. *Power System Technology*: 1–14 [2023-03-22]. <http://kns.cnki.net/kcms/detail/11.2410.tm.20230310.1705.003.html>.
- [28] 余昊杨, 武昕. 基于一维卷积神经网络的非侵入工业负荷事件检测方法[J]. 计算机应用, 2022, 42(增刊 2): 277–284.
- YU Haoyang, WU Xin. Non-invasive industrial load event detection method based on one-dimensional convolutional neural network[J]. *Journal of Computer Applications*, 2022, 42(S2): 277–284.
- [29] 张未, 余成波, 王士彬, 等. 基于 VMD-LSTM-LightGBM 的多特征短期电力负荷预测[J]. 南方电网技术, 2023, 17(2): 74–81.
- ZHANG Wei, YU Chengbo, WANG Shibin, *et al.* Multi-featured short-term power load forecasting based on VMD-LSTM-LightGBM[J]. *Southern Power System Technology*, 2023, 17(2): 74–81.

作者简介:

周颖(1993—), 女, 硕士, 工程师, 从事电力电量分析预测研究, E-mail: hgzhouying@163.com;

白雪峰(1997—), 男, 硕士研究生, 从事电力电量



分析预测研究, E-mail: 884973072@qq.com;

王阳 (1985—), 女, 博士, 高级工程师, 从事电力
电量分析预测研究, E-mail: wang-yang@sgcc.com.cn;

邱敏 (1992—), 男, 博士, 工程师, 从事电力电量
分析预测研究, E-mail: qiumin@epri.sgcc.com.cn;

孙冲 (1983—), 男, 高级工程师, 从事电力电量分

析预测研究, E-mail: sunchong@163.com.cn;

武亚杰 (1993—), 男, 从事电力电量分析预测研
究, E-mail: wuyajie@epri.sgcc.com.cn;

李彬 (1983—), 男, 通信作者, 博士, 副教授, 从
事需求响应和负荷预测研究, E-mail: direfish@163.com。

(责任编辑 李博)

Analysis and Evolution Trend of Temperature-Sensitive Loads for Virtual Power Plant Operation

ZHOU Ying¹, BAI Xuefeng², WANG Yang³, QIU Min¹, SUN Chong⁴, WU Yajie¹, LI Bin²

(1. Beijing Key Laboratory of Demand Side Multi-Energy Carriers Optimization and Interaction Technique (China Electric Power Research Institute), Beijing 100192, China; 2. Department of Electrical and Electronic Engineering, North China Electric Power University, Beijing 102206, China; 3. State Grid Corporation of China, Beijing 100031, China; 4. Marketing Service Center of State Grid Hebei Electric Power Co., Ltd., Shijiazhuang 050081, China)

Abstract: With the frequent occurrence of extreme weather, the electricity consumption of temperature-sensitive loads is increasing year by year. As a high-quality regulation resource of virtual power plant (VPP), temperature-sensitive loads urgently need to be analyzed for the impact of meteorological changes on them. Due to the influence of abnormal weather such as extreme high temperature and large-scale cold waves, temperature-sensitive loads fluctuate violently. Conventional analysis and prediction methods are not adaptable to the extreme meteorological scenarios. Aiming at the problem of insufficient sample data and prediction accuracy of temperature-sensitive loads under cold wave weather, this paper proposes a daily maximum load prediction method for temperature-sensitive loads under the condition of small sample in cold wave weather. In this method, the TimeGAN is used to expand the small sample data during the cold wave period, and then the CNN-LSTM network is used to predict the daily maximum load during the cold wave period. Finally, the model is verified by the load data of a province in China during the winter period in the past two years. The results show that the prediction results of the proposed model are better than those of other models, with the prediction accuracy of the daily maximum load on the verification set being 99.5%.

This work is supported by Science and Technology Project of SGCC (Regional Power Supply and Consumption Comprehensive Pre-Treatment Supporting Heavy Overload Station Area Governance, No.5108-202218280A-2-379-XG).

Keywords: temperature sensitive load forecasting; cold wave; time series generative adversarial network; virtual power plant; convolutional neural network; long short-term memory neural network