

计及用电行为模式的区域商业建筑负荷预测方法

李洁, 顾水福, 周磊, 李亚飞, 刘乙, 朱超群

(国网江苏省电力有限公司 苏州供电公司, 江苏 苏州 215004)

摘要:为充分利用智能电表采集的细粒负荷数据并提高区域商业建筑负荷预测的精确度,提出一种基于用电行为模式的区域商业建筑负荷预测方法。首先,基于均值方差归一化方法对采集到的负荷数据进行标准化处理,通过肘方法确定聚类数目后进行k-Shape聚类,实现区域商业建筑负荷不同用电行为模式的提取;其次,针对大规模商业建筑负荷预测问题,考虑区域内大量商业建筑负荷预测时耗费大量内存资源却难以实现较准确预测问题,提出一种改进的Informer模型,该模型通过聚类算法识别具有相似用电行为模式的商业建筑,并充分考虑智能电表采集的异常负荷数据对模型训练结果的影响,能够良好的解决大规模商业建筑负荷预测精度不高问题;最后,采用加利福尼亚州商业建筑负荷进行实验,实验结果表明所提方法能够有效提高区域商业建筑负荷预测精度。

关键词:商业建筑;负荷预测;k-Shape聚类;用电行为模式;Informer模型

Regional commercial building load forecasting method considering electricity consumption behavior patterns

LI Jie, GU Shuifu, ZHOU Lei, LI Yafei, LIU Yi, ZHU Chaoqun

(Suzhou Power Supply Company, State Grid Jiangsu Electric Power Co., Ltd., Suzhou 215004, China)

Abstract: A region-based commercial building load forecasting method based on electricity consumption behavior patterns is proposed to fully exploit the fine-grained load data collected by smart meters and to improve the accuracy of regional commercial building load forecasting. Firstly, the mean-variance normalization method is used to standardize the collected load data. Then, to extract different electricity consumption behavior patterns in regional commercial building loads, the elbow method is used to determine the number of clusters, followed by k-Shape clustering. Next, an improved Informer model is introduced to address the challenge of predicting large-scale commercial building loads within a region, which often requires significant memory resources while struggling to achieve high accuracy. This model uses clustering algorithms to identify commercial buildings with similar electricity consumption patterns and accounts for the impact of anomalous load data collected by smart meters on the training results. The proposed model effectively addresses the problem of low accuracy in predicting load for large commercial buildings. Finally, experiments are conducted using commercial building loads in California. The experimental results demonstrate the effectiveness of our proposed method in the improvement of the accuracy of regional commercial building load forecasting.

Key words: commercial building; load forecasting; k-Shape clustering; electricity consumption behavior patterns; Informer model

0 引言

智能电表的推广使用使得电力企业可获取更多电力负荷用户的细粒用电数据,但大量用户用电细粒数据被收集后并未被充分利用,其中隐藏的客户用电行为习惯对于改进负荷预测精度具有至关重要的作用。随着智能电网建设的不断推进,利用客户的历史负荷数据分析预测用户的未来用电量,并针对不同客户提出个性化用电政策、预测区域级负荷水平以更好地制定发电计划的信息挖掘技术

将成为亟需解决的问题。

针对一定区域内商业建筑负荷的分析,聚类算法可以高效地从电力消费者负荷数据中区分出不同的消费群体并且提取出每一类消费者的用电行为模式,进一步提高负荷预测的准确性。智能电表采集的时间序列负荷数据可为聚类和负荷预测提供全新的角度,即从时间序列进行商业负荷的聚类和预测,从而实现负荷用电行为模式的准确识别和负荷的精准预测。

鉴于聚类算法在异常检测^[1]、特征提取^[2]、模式识别^[3]等方面的广泛应用和优异表现,其在近年来已被广泛研究^[4-5]。聚类算法按照输入特征的不同可分为直接聚类和间接聚类,直接聚类使用原始负

荷数据进行聚类分析,如k-means^[6]、模糊C均值^[7]等算法。文献[8]针对配电网负荷数据特点,提出一种基于改进萤火虫算法和k-means算法结合的配电网负荷聚类特性分析方法,解决了聚类算法会出现因初始中心不同造成聚类结果差异大的问题。间接聚类通过提取若干用电特征,并对这些特征进行聚类分析。文献[9]提出一种结合多维缩放和一种新的集成簇间、簇内欧式距离的加权k-means方法,解决了传统负荷聚类方法难以有效处理海量化的高维负荷数据的问题。本文重点围绕区域内商业建筑负荷进行数据分析与预测,智能电表所采集的大规模商业建筑负荷数据中隐含着待挖掘的规律性和周期性特征信息,时间序列聚类算法在面对此种大规模的负荷数据,在未有先验知识的情况下进行用电行为模式识别具有很大优势^[10],因此本文采用时间序列聚类k-Shape算法来解决商业建筑负荷的模式识别问题。

针对电力负荷预测问题,预测模型可分传统的统计模型和基于机器学习的模型^[11],传统的统计模型以时间序列分析、ARIMA模型、指数平滑法为代表^[12-14]。基于机器学习的模型以神经网络、支持向量机、回归树、随机森林为代表^[15-18]。文献[19]提出了一种基于小波分解和支持向量机相结合的模式,并成功将其应用于预测商业建筑电力负荷。此外,Informer模型将传统的统计模型和机器学习模型相结合,在时间序列负荷预测方面具有良好效果^[20]。本文基于Informer模型并针对商业建筑负荷的数据特征进行改进,充分考虑区域内大量商业建筑负荷预测时耗费大量内存资源却难以实现较准确预测问题,提出一种改进的Informer模型,该模型可解决大规模商业建筑负荷难以快速准确预测的问题,并通过算例试验证明了其在商业建筑负荷预测方面的准确性与适用性。

1 k-Shape 聚类

通过智能电表采集的时间序列负荷数据隐含着大量用户用电行为信息,与传统的聚类算法相比,时间序列聚类并未舍弃时间信息,可以最大程度的发现用户在不同的时间周期内的用电习惯与行为模式^[21]。时间序列聚类可分为全时间序列聚类、子序列时间序列聚类和时间点聚类,k-Shape基于形状的时间序列聚类是全时间序列聚类的其中一种^[22],它基于形状对一组时间序列的相似性进行聚类。相似性度量、质心的计算以及聚类算法是影响时间序列聚类效

果的3个核心部分,以下将对其进行详细介绍。

1.1 相似性度量

相似性度量是衡量不同时间序列之间相似性的重要指标,较典型的度量方法有欧式距离(euclidean distance, ED)和(dynamic time warping, DTW)^[23], k-Shape提出一种基于形状的距离度量(shape-based distance, SBD)。考虑两个时间序列 $\mathbf{x} = \{x_1, x_2, \dots, x_m\}$ 、 $\mathbf{y} = \{y_1, y_2, \dots, y_m\}$, 固定其中一个时间序列 $\mathbf{y} = \{y_1, y_2, \dots, y_m\}$, 不断移动 $\mathbf{x} = \{x_1, x_2, \dots, x_m\}$ 并计算与 $\mathbf{y} = \{y_1, y_2, \dots, y_m\}$ 的内积,如式(1)所示。在对负荷数据进行处理前,需将时间序列 \mathbf{x} 处理为均值 μ 为0且方差 σ 为1的序列 $\mathbf{x}' = (\mathbf{x} - \mu)/\sigma$, 保证序列缩放的不变性

$$\mathbf{x}_{(s)} = \begin{cases} (\underbrace{0, \dots, 0}_{|s|}, x_1, x_2, \dots, x_{m-s}) & s \geq 0 \\ (x_{1-s}, \dots, x_{m-1-s}, x_m, \underbrace{0, \dots, 0}_{|s|}) & s < 0 \end{cases} \quad (1)$$

式中: s 的正负分别为两序列滑动的方向, s 绝对值为移动的距离。式(1)计算过程如图1所示。




图1 滑动计算过程

Fig. 1 Sliding calculation process

为得到距离度量,计算全部 $\mathbf{x}_{(s)}$ 得到互相关系数

$$C_{C,w}(\mathbf{x}, \mathbf{y}) = R_{w-m}(\mathbf{x}, \mathbf{y}), \quad w \in \{1, 2, \dots, 2m-1\} \quad (2)$$

$$R_s(\mathbf{x}, \mathbf{y}) = \begin{cases} \sum_{l=1}^{m-s} x_{l+s} y_l & s \geq 0 \\ R_{-s}(\mathbf{y}, \mathbf{x}) & s < 0 \end{cases} \quad (3)$$

计算使得 $C_{C,w}(\mathbf{x}, \mathbf{y})$ 取得最大值时 w 的数值,并由式(2)与式(3)计算得序列 \mathbf{x} 对应的最佳位移距离 $\mathbf{x}_{(s)}$, 其中 $s = w - m$ 。将式(2)按式(4)归一化至 $[-1, 1]$, 数值“1”代表着两时间序列完全相似

$$N_{CC,c}(\mathbf{x}, \mathbf{y}) = \frac{C_{C,w}(\mathbf{x}, \mathbf{y})}{\sqrt{R_0(\mathbf{x}, \mathbf{x})R_0(\mathbf{y}, \mathbf{y})}} \quad (4)$$

由此可得到基于形状的距离 S_{BD} 的计算

$$S_{BD}(\mathbf{x}, \mathbf{y}) = 1 - \max_w (N_{CC,c}(\mathbf{x}, \mathbf{y})) \quad (5)$$

上述对数据的处理建立了衡量数据的相似性度量,并保证了数据的位移不变性。

1.2 簇原型

经典的k-means算法将平均序列的每个坐标计算为所有序列对应坐标的算术平均值,其可以快速

描述簇的特性,但在时间序列聚类质心计算过程中的应用仍有待改进。k-Shape 算法将质心的计算视为优化问题进行处理,目标为找到与所有时间序列最相似的序列,而式(4)可描述序列之间的相似性,即数值越大越相似,故可将质心的计算问题转化为通过寻优算法求式(6)的最大值问题

$$\begin{aligned} \mu_k &= \arg \max_{\mathbf{x} \in P_k} N_{CC,c}(\mathbf{x}, \mu)^2 \\ &= \arg \max_{\mu} \sum_{\mathbf{x} \in P_k} \left(\frac{\max_{\mathbf{u} \in CC,c}(\mathbf{x}, \mu)}{\sqrt{R_0(\mathbf{x}, \mathbf{x})R_0(\mu, \mu)}} \right)^2 \end{aligned} \quad (6)$$

2 Informer模型

近年来,深度学习模型中的Transformer模型在处理时间序列问题的能力方面远远优于传统的循环神经网络(recurrent neural network, RNN)模型^[24],针对时间序列数据处理与预测问题而出现的Informer模型改进了Transformer在解决长时间序列预测问题时自关注的二次计算、长输入叠加层的内存瓶颈、预测长输出的速度下降这3个问题,本节将对其进行介绍,并针对商业建筑负荷预测提出改进Informer模型。

2.1 自注意力机制

在Transformer中作者提出的传统的注意力机制通过输入(Query, Key)后计算缩放点积

$$A(Q, K, V) = \text{soft max} \left(\frac{QK^T}{\sqrt{d}} \right) V \quad (7)$$

式中: $Q \in XW^q, K \in XW^k, V \in XW^v$, 其中 W^q, W^k, W^v 分别表示对应的可训练参数矩阵; d 为输入维度。Informer作者们经过实验和观察发现,传统注意力计算方法的自我注意力“稀疏性”得分呈现长尾分布,即查询矩阵 Q 中仅有少部分对注意力的贡献较大,故在Informer模型中,注意力计算方式被改进为如式(8)所示

$$A(Q, K, V) = \text{soft max} \left(\frac{\bar{Q}K^T}{\sqrt{d}} \right) V \quad (8)$$

式中: \bar{Q} 为一个经过注意力筛选且与 Q 大小相同的稀疏矩阵,它仅包含对注意力贡献较大的查询矩阵。

2.2 编码和解码结构

Informer延续了Transformer的编码器和解码器结构,其结构可由图2表示。

编码器接收长序列输入,通过多头概率稀疏自注意力模块和自注意力蒸馏模块,得到特征表示。多头概率稀疏自注意力机制利用稀疏矩阵来替代原来的注意力矩阵,大幅减少算力需求的同时并保持的良好性能。

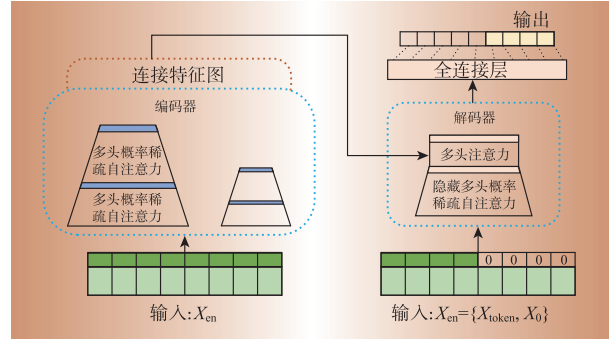


图2 Informer的总体框架

Fig. 2 Overall framework of Informer

解码器接收长序列输入,通过多头注意力与编码特征进行交互,最后直接预测输出目标部分。Informer采用的一次生成式预测方式比步进方式推理速度更快且效果相当。

2.3 损失函数

原Informer采用均方误差(mean squared error, MSE)作为损失函数进行反向传播训练,其计算公式如式(9)所示

$$MSE = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (9)$$

式中: m 为训练样本的个数; y_i 为商业用户实际负荷值; \hat{y}_i 为模型输出的预测值。另一常用的回归损失函数为平均绝对误差(mean absolute error, MAE),其计算公式如式(10)所示

$$MAE = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \quad (10)$$

本文采用Huber损失函数进行商业建筑负荷预测模型的训练,其计算公式如式(11)所示

$$\eta_{\text{Huber}} = \begin{cases} \frac{1}{2}(y_i - \hat{y}_i)^2 & |y_i - \hat{y}_i| \leq \delta \\ \delta |y_i - \hat{y}_i| - \frac{1}{2}\delta^2 & |y_i - \hat{y}_i| > \delta \end{cases} \quad (11)$$

式中: δ 为Huber损失函数的超参数,在本文的模型训练中 δ 设置为0.5。将上述3种损失函数绘制于同一图中,如图3所示。

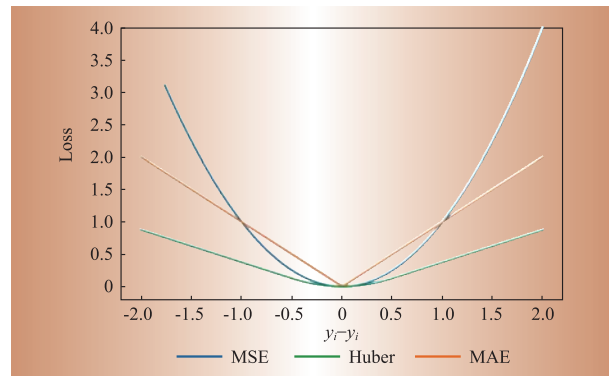


图3 3种损失函数

Fig. 3 3 loss functions

图3为假设真实值 $y=0$,预测值在 $[-2,2]$ 之间变化的3种损失变化图,横轴为不同的预测值,纵轴为3种损失值。随着预测与真实值误差的增加, MSE呈平方增长, MAE呈线性增长。

由图3可知, MSE相比于MAE的收敛速度更快,其损失的梯度为 $-\hat{y}_i$,而后的损失梯度为 ± 1 ,因此在模型训练过程中MSE与MAE之间梯度的差异最终导致了MSE更快的收敛速度,但又由于MAE损失的梯度固定的,因此当训练数据中出现一个较大的异常值时,与误差呈平方关系的MSE会产生一个较大的损失,这个损失对于模型的训练是极为不利的,而采用MAE进行模型训练时并不会因此受到异常值的巨大影响,MAE对于异常值具有更好的鲁棒性。

在进行区域内商业建筑负荷预测时,面对大规模训练数据有两点是不得不考虑的,一方面训练的准确性是必须得到保证的,另一方面训练所需的时间也是不容忽略的重要因素。因此为了不以损失训练速度为代价来提高模型训练的准确性,本文提出采用Huber作为损失函数的改进Informer模型进行商业建筑负荷的预测。Huber损失函数具有超参数,可通过设置适当的 δ 以适应不同类型的负荷预测模型训练。当预测偏差小于 δ ,则采用类似于MSE的损失计算方法,提高在损失的梯度较小时的模型收敛速度;当预测偏差大于 δ ,则采用类似于MAE的线性误差,减少异常值导致的较大损失值对于模型训练的影响,提高模型对于异常值的鲁棒性。

3 实验分析

3.1 实验数据集

实验使用了公开可用的数据集,该数据集针对美国所有气候区域的主要住宅和商业建筑类型和最终用途进行了校准和验证的15分钟分辨率负荷曲线。本文采用其中的加利福尼亚州2018年613个商业用户的负荷情况进行实验。

3.2 k-Shape 聚类

k-Shape 聚类需要提前确定聚类的数目,采用核心指标为误差平方和(sum of the squared errors, SSE)的肘方法来确定聚类数目 K ,其计算公式定义如式(12)

$$S_{SE} = \sum_{i=1}^k \sum_{p \in C_i} |p - m_i|^2 \quad (12)$$

式中: C_i 为第 i 个簇; p 为 C_i 的样本点; m_i 为 C_i 的簇原型; SSE为所有样本的聚类误差。为避免不同用户负荷量差别过大对聚类产生影响,对原始数据

进行均值方差归一化,并计算不同聚类数目的所有样本误差平方和,计算结果如图4所示。




图4 不同聚类数目对误差平方和的影响

Fig. 4 Impact of different number of clusters on SSE

根据肘方法可以发现当聚类数目到达6时,误差平方和的变化缓慢,这就是最终要的聚类簇数。对负荷进行k-Shape聚类得到结果如图5所示,其中纵坐标为归一化后的无量纲历史负荷数据,其纵坐标为0即负荷平均值为0,纵坐标正值、负值分别表示高于和低于负荷平均值。

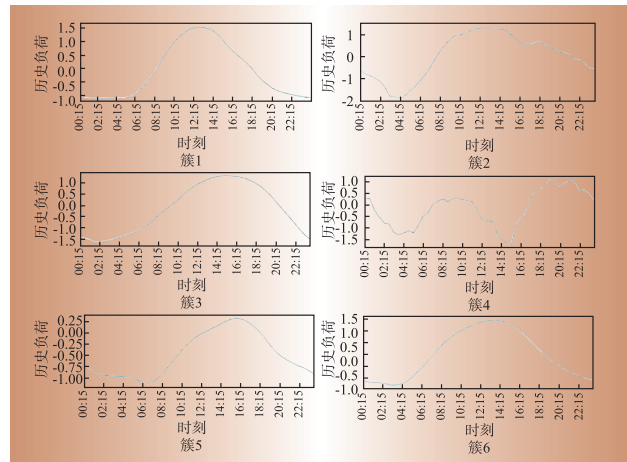


图5 k-Shape 聚类的结果

Fig. 5 Results of k-Shape clustering

用电行为模式是负荷变化特性的综合体现,其包含着负荷变化的所有信息如用电负荷曲线、用电时间、用电量、用电率、用电功率、能耗结构等指标,本文针对商业建筑负荷所考虑的用电行为模式仅包含部分体现商业建筑营业模式的典型指标:峰谷值数目、峰谷值时段、峰谷差,并通过结合实际的商业建筑类型的方式对负荷特性进行分析。

根据图5结果,按照峰值个数可将商业负荷分为单峰型和双峰型,聚类结果簇1中的商业负荷类型为小学、中学、零售购物中心、独立零售店,其均为严格的日耗能型商户,且在12:00附近达到一天

的耗能峰值,22:00后完全歇业并保持负荷谷值至次日05:00左右。簇2中的商户类型为小旅馆和大型酒店,相较于前一种商业负荷类型其具有更强的负荷波动性,负荷水平整体较高,峰值时间持续时间长,负荷谷值时间短且其出现在凌晨03:00—05:00。簇3中的商户类型为快餐店和全方位服务的餐厅,与簇1一样均属于严格的日耗能型商户,单峰值出现在15:00附近,23:00—次日05:30负荷水平较低为歇业时间。簇4中的商业负荷类型为大型旅馆,其负荷变化受众多随机住户的影响且住户随机性强,因此负荷具有强波动性,负荷整体水平较低,负荷双峰值出现在09:00以及21:00,夜间谷值特征与簇2类似,日间谷值出现在14:00附近。簇5中的商户类型为小型办公室、中型办公室、大型办公室和诊所,负荷与簇4一样受随机用户影响,但该类用户耗能少且具有较规律的用电习惯,因此负荷整体水平较低且较稳定。簇6中的商户类型较多有小旅馆、零售购物中心、独立零售店、医院和仓库,其与簇1一样是日耗能型但夜间仍有少量负荷,且相较于簇1负荷峰值出现了偏移即出现在14:00附近。

3.3 Informer 预测

本文的实验环境为python3.9,pytorch 2.0.0 框架,Windows 11,16.0GB,12th Gen Intel (R) Core (TM) i7-12700H 2.70 GHz,NVIDIA GeForce RTX 3060 Laptop GPU。

根据3.2节聚类结果,分别对k-Shape的6个聚类的簇原型进行训练,本实验选取LSTM进行对比试验,为消除负荷量纲差别较大引起的误差,在历史负荷数据输入到改进的Informer模型进行训练前进行重采样和归一化处理,本文使用的原数据为每15 min采样一次,对原数据进行重采样使得所得历史负荷数据为每30 min采样一次。

以对簇1输入数据未来一天的负荷变化情况预测为例,首先,分别采取历史负荷数据的80%、10%、10%作为训练数据、验证数据和测试数据,初始化模型的参数;其次,由于训练数据采样频率为每30分钟采样一次,故模型的预测步长设置为48;此外,采用Adam优化器且在 $[0,1]$ 范围内调整学习率,并根据训练数据集调整模型的批尺寸、丢弃率、编码器个数、解码器个数、训练周期epoch等参数。表1为对簇1未来一天负荷变化情况预测的模型关键参数设置情况。

图6是预测簇1未来一天即48个时间点负荷的结果,其中GroundTruth为实际负荷情况,横坐标为预测时间点,纵坐标为归一化后的负荷数据,其纵坐标为0即负荷平均值为0,纵坐标正值、负值分别

表1 预测簇1未来一天负荷模型的关键参数

Table 1 Key parameters of model for predicting load of the next day of cluster 1

参数名称	设置情况
batch_size	32
dropout	0.05
learning_rate	0.000 1
enc_in	1
dec_in	1
n_heads	16
e_layers	1
s_layers	[3, 2, 1]
c_out	1
d_model	1 024
seq_len	144
label_len	96
pred_len	48

注:batch_size为批尺寸;dropout为在网络训练过程中,随机丢弃神经元的概率;learning_rate为学习率;enc_in、dec_in分别为编码器和解码器的维度;n_heads为多头自注意力机制中多头的个数;e_layers、s_layers分别为编码层和解码层的层数;c_out为输出序列的维度;d_model为自注意力层的输入和输出向量维度;seq_len为编码器的输入序列长度;label_len为解码器的开始令牌长度;pred_len为预测序列长度。

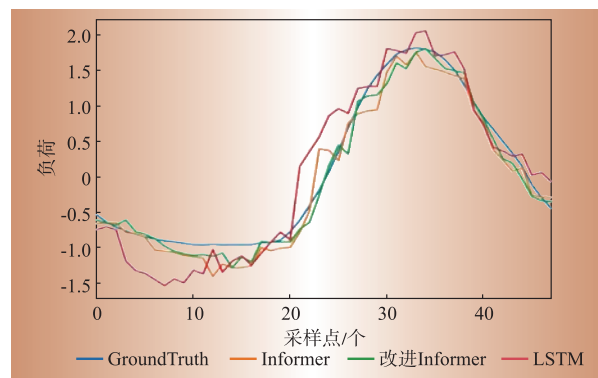


图6 3种算法的预测结果

Fig. 6 Forecasting results of 3 algorithms

表示高于和低于负荷平均值,通过图6可以直观的看到改进的Informer的预测结果曲线更加地接近真实负荷曲线,其在商业建筑负荷预测方面的表现优于广泛使用的LSTM模型以及原始Informer模型。在进行负荷预测时,当预测的结果对时间距离较远的信息产生依赖时,会导致无法有效快速地获取这部分信息而产生长期依赖问题,LSTM模型的提出有效解决了预测的长期依赖问题,LSTM通过引入门机制对特征的流通和损失进行控制,而Informer模型继承Transformer模型的注意力机制在解决长时间序列的预测问题时的表现是优于门机制的,且其通过加入多头概率稀疏自注意力机制进一步提高运算的速度和准确度。

为验证改进的Informer模型在更多商业建筑负

荷预测方面的适用性,分别对k-Shape聚类的6类用电行为模式的商业建筑负荷进行模型训练,并进行多种预测长度的模型训练测试,分别预测未来半天、一天和两天的负荷情况,即网络预测步长分别设置为24、48、96。经过训练可得到如表2所示结果。

表2 6类用电行为模式的3种算法预测结果

Table 2 Forecasting results of 3 algorithms for 6 types of electricity consumption behavior patterns

算法	簇号						
	1	2	3	4	5	6	
LSTM	24	0.116	0.058	0.124	0.371	0.226	0.068
	48	0.133	0.090	0.227	0.724	0.435	0.098
	96	0.261	0.081	0.276	0.908	0.509	0.141
Informer	24	0.101	0.046	0.111	0.277	0.169	0.060
	48	0.121	0.068	0.183	0.624	0.181	0.078
	96	0.132	0.072	0.203	0.668	0.369	0.102
改进Informer	24	0.022	0.038	0.052	0.304	0.125	0.034
	48	0.024	0.044	0.072	0.922	0.102	0.059
	96	0.114	0.088	0.108	1.012	0.288	0.072

由表2可知,以Huber损失函数替代原Informer中的MSE函数作为损失函数来预测商业负荷是切实可行的。可以看出,改进Informer相较另外两个模型在各用电行为模式下有着更好的表现。在负荷波动性较强的簇4负荷预测时Informer表现出较好的预测准确性,在其余的用电行为模式下均是改进Informer表现最佳。

在每个用电行为模式的商业建筑准确预测的基础上,针对不同的商业建筑负荷采用其表现性能最佳的预测算法进行预测,并将最后的预测结果进行求和便可得到较准确的区域商业建筑负荷预测值。

本文所采用的k-Shape聚类算法在时间序列数据聚类方面具有较广泛应用,且其聚类数目的确定由上文分析可知并不需要相关的先验知识,而是可根据手肘法或轮廓系数法进行综合确定,故在其他具有多种模式的建筑负荷模式提取问题上k-Shape聚类算法具有较强的适用性。此外,本文所提改进Informer模型可应用于其他时间序列负荷数据的预测方面,其在模型训练过程中可根据负荷特征的不同调整各具体参数使其具有较准确预测结果,并在面对具有异常值的负荷数据时仍能保证预测的准确性。故本文所提针对商业建筑负荷预测的处理方法,在解决具有较明显模式区别的区域负荷预测问题时仍具有一定的泛化适用性。

4 结束语

本文将基于Transformer的Informer模型应用于

商业建筑负荷预测,从时间序列角度实现商业建筑负荷精准预测。通过k-Shape聚类算法对具有相似用电行为模式的商业建筑进行识别,针对大规模商业建筑负荷预测问题,考虑区域内大量商业建筑负荷预测时耗费大量内存资源却难以实现较准确预测问题,提出一种改进的Informer模型,并通过实验比较LSTM与改进Informer模型在不同预测范围下的效果,结果表明,改进的Informer模型能够有效实现多种用电行为模式的商业建筑负荷的精准预测。D

参考文献:

- [1] 王建元,张少锋. 基于线性判别分析和密度峰值聚类的异常用电模式检测[J]. 电力系统自动化, 2022, 46(5): 87-98.
WANG Jiayuan, ZHANG Shaofeng. Anomaly detection for power consumption patterns based on linear discriminant analysis[J]. Automation of Electric Power Systems, 2022, 46(5): 87-98.
- [2] 张露,颜宏文,马瑞. 基于改进DBSCAN-RNN的电力负荷建模及可调特征提取[J]. 智慧电力, 2023, 51(3): 39-45.
ZHANG Lu, YAN Hongwen, MA Rui. Power load modeling and adjustable feature extraction based on improved DBSCAN-RNN[J]. Smart Power, 2023, 51(3): 39-45.
- [3] 白东壮,田世明,邹毅豪,等. 基于FDA的居民用户空调用电行为分类分析方法[J]. 智慧电力, 2022, 50(3): 44-49, 71.
BAI Dongzhuang, TIAN Shiming, ZOU Yihao, et al. Classification analysis method of residential air conditioning electricity consumption behavior based on functional data analysis model[J]. Smart Power, 2022, 50(3): 44-49, 71.
- [4] 郑乐,徐青山,冯小峰. 基于层次聚类算法与SA-LSSVM的短期负荷预测研究[J]. 电力需求侧管理, 2022, 24(5): 51-57.
ZHEN Le, XU Qingshan, FENG Xiaofeng. Short-term load forecasting based on hierarchical clustering algorithm and ISA-LSSVM[J]. Power Demand Side Management, 2022, 24(5): 51-57.
- [5] 苏晨,邹云峰,祝宇楠,等. 一种基于差分隐私的电力客户数据隐私保护聚类方法[J]. 电力需求侧管理, 2023, 25(2): 101-106.
SU Chen, ZOU Yunfeng, ZHU Yunan, et al. Privacy-preserving clustering method of power customer data based on differential privacy[J]. Power Demand Side Management, 2023, 25(2): 101-106.
- [6] SINAGA K P, YANG M S. Unsupervised k-means clustering algorithm [J]. IEEE Access, 2020, 8: 80 716-

- 80 727.
- [7] BEZDEK J C, EHRlich R, FULL W. FCM: The fuzzy c-means clustering algorithm[J]. *Computers & Geosciences*, 1984, 10(2):191-203.
- [8] 王继东, 顾志成, 葛磊蛟, 等. 改进萤火虫算法与K-means算法结合的配电网负荷聚类特性分析[J]. *天津大学学报(自然科学与工程技术版)*, 2023, 56(2):137-147.
WANG Jidong, GU Zhicheng, GE Leijiao, et al. Load clustering characteristic analysis of the distribution network based on the combined improved firefly algorithm and k-means algorithm[J]. *Journal of Tianjin University (Science and Technology)*, 2023, 56(2):137-147.
- [9] 刘诗语, 吴鸣, 李睿哲. 基于多维缩放和KICIC的电力负荷聚类[J]. *科学技术与工程*, 2023, 23(3):1 096-1 103.
LIU Shiyu, WU Ming, LI Ruizhe. Power load curve clustering research based on multidimensional scaling and KICIC[J]. *Science Technology and Engineering*, 2023, 23(3):1 096-1 103.
- [10] 李丹妮. 基于时间序列聚类的工业用电模式识别[D]. 上海: 上海财经大学, 2020.
LI Danni. Industrial electricity pattern recognition based on time series clustering [D]. Shanghai: Shanghai University of Finance and Economics, 2020.
- [11] MADHULATHA T S. An overview on clustering methods [J]. *IOSR Journal of Engineering*, 2012, 2(4).
- [12] CONTRERAS J, ESPINOLA R, Nogales F J, et al. ARIMA models to predict next day electricity prices[J]. *IEEE Transactions on Power Systems*, 2003, 18(3):1 014-1 020.
- [13] 卢永芳, 程志磊, 王晓卫, 等. 基于时序指数平滑法的风电场功率预测研究[J]. *工矿自动化*, 2012, 38(8):75-78.
LU Yongfang, CHENG Zhilei, WANG Xiaowei, et al. Research of power prediction of wind farm based on sequential index smoothing method [J]. *Journal of Mine Automation*, 2012, 38(8):75-78.
- [14] 吴浩, 齐放, 张曦, 等. 基于小波包分解与最小二乘支持向量机的用户侧净负荷预测[J]. *现代电力*, 2023, 40(2):192-200.
WU Hao, QI Fang, ZHANG Xi, et al. User-side net load forecasting based on wavelet packet decomposition and least squares support vector machine [J]. *Modern Electric Power*, 2023, 40(2):192-200.
- [15] 戴明明, 王康, 李强, 等. 基于天气分类和卷积神经网络的短期负荷预测方法[J]. *电力需求侧管理*, 2023, 25(3):93-98.
DAI Mingming, WANG Kang, LI Qiang, et al. Short-term load forecasting method based on weather classification and convolutional neural network [J]. *Power Demand Side Management*, 2023, 25(3):93-98.
- [16] 孙志翔, 丁彬, 孙晓燕. 基于迁移学习和GRU网络的新建小区负荷预测[J]. *电力需求侧管理*, 2022, 24(1):55-62.
SUN Zhixiang, DING Bin, SUN Xiaoyan. New community load prediction based on transfer learning and GRU network [J]. *Power Demand Side Management*, 2022, 24(1):55-62.
- [17] 魏联滨, 王彬, 王莹, 等. 基于气象相似日选取与提升回归树的光伏发电短期功率预测[J]. *电子器件*, 2022, 45(1):183-188.
WEI Lianbin, WANG Bin, WANG Ying, et al. Short-Term power forecast of photo voltaic power generation based on weather similarity day and boosting regression tree [J]. *Chinese Journal of Electron Devices*, 2022, 45(1):183-188.
- [18] 胡兆龙, 胡俊建, 彭浩, 等. 基于深度随机森林算法的短期用户负荷预测——以金华地区为例[J]. *电子科技大学学报*, 2023, 52(3):430-437.
HU Zhaolong, HU Junjian, PENG Hao, et al. Short-Term user load forecasting based on deep random forest: Take jinhua city as an example [J]. *Journal of University of Electronic Science and Technology of China*, 2023, 52(3):430-437.
- [19] 杨屹洲, 方瑞明, 黄文权, 等. 应用小波变换和支持向量机的商业电力负荷预测[J]. *华侨大学学报(自然科学版)*, 2015, 36(2):142-146.
YANG Yizhou, FANG Ruiming, HUANG Wenquan, et al. Commercial power load forecasting using wavelet Transform and SVM [J]. *Journal of Huaqiao University (Natural Science)*, 2015, 36(2):142-146.
- [20] ZHOU H, ZHANG S, PENG J, et al. Informer: beyond efficient transformer for long sequence timeseries forecasting [C]//Proceedings of the AAAI conference on artificial intelligence. 2021, 35(12):11 106-11 115.
- [21] AGHABOZORGI S, SHIRKHORSHIDI A S, WAH T Y. Timeseries clustering- a decade review [J]. *Information Systems*, 2015, 53:16-38.
- [22] PAPARRIZOS J, GRAVANO L. K-Shape: efficient and accurate clustering of time series [J]. *ACM SIGMOD Record*, 2015, 45(1):69-76.
- [23] LIBERTI L, LAVOR C, MACULAN N, et al. Euclidean distance geometry and applications [J]. *SIAM Review*, 2014, 56(1):3-69.
- [24] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. *Advances in Neural Information Processing Systems*, 2017, 30.

作者简介:

李洁(1972),女,江苏苏州人,硕士,高级工程师,研究方向为电力负荷管理及需求响应。

(责任编辑 王 蕊)