

# 基于开发智慧云平台的日前建筑用电负荷预测方法研究

潘广旭<sup>1</sup>, 宫池玉<sup>1</sup>, 李兴玉<sup>1</sup>, 胡军<sup>1</sup>, 李英杰<sup>1</sup>, 王瑞琪<sup>2</sup>

(1. 国网山东省电力公司日照供电公司, 山东 日照 276800;

2. 国网山东综合能源服务有限公司, 山东 济南 250002)

**摘要:**作为电力系统设计规划、运行调度的重要一环,电力负荷预测受到强随机性、低精度的困扰,同时先进预测算法的落地实施关联数据管理系统,而传统数据管理系统底层数据资源传输与治理、预测信息应用十分不便。为了克服以上问题,基于云平台,在实现数据高效采集与治理的基础上,为电负荷预测提供天气预报以及历史电负荷信息;在日前负荷预测过程中,针对单一长短期记忆(LSTM)神经网络对时序数据挖掘能力不充分的情况,利用小波变换(WT)细化时序负荷高频分量,同时借助下一日温度、相对湿度预报信息,提升日前电负荷预测精度。结果表明,所提WT-LSTM方法表现了良好的预测效果,其两日均方根误差分别为185.56和179.56,比传统的LSTM网络预测精度分别提高了61.48%和12.51%。

**关键词:**电力负荷预测;云平台;长短期记忆神经网络;小波变换

**中图分类号:**TM715 **文献标识码:**A **DOI:**10.19457/j.1001-2095.dqed22877

## Research on Day-ahead Forecasting Method of Building Electricity Load Based on the Development of Smart Cloud Platform

PAN Guangxu<sup>1</sup>, GONG Chiyu<sup>1</sup>, LI Xingyu<sup>1</sup>, HU Jun<sup>1</sup>, LI Yingjie<sup>1</sup>, WANG Ruiqi<sup>2</sup>

(1. State Grid Shandong Electric Power Co., Ltd. Rizhao Power Supply Company, Rizhao 276800, Shandong, China; 2. State Grid Shandong Comprehensive Energy Service Co., Ltd., Jinan 250002, Shandong, China)

**Abstract:** As an essential part of power system design and operation scheduling, electric load forecasting is troubled by strong randomness and low accuracy. Moreover, the application of advanced forecasting algorithms is associated with data management system, while the traditional data management system is very inconvenient for the transmission and management of the data resources and the application of prediction information. In order to overcome the above problems, based on the cloud platform, weather forecast and historical electric load information was provided for electric load prediction on the basis of achieving efficient data collection and management. In the process of day-ahead load forecasting, aiming at the insufficient ability of single long short-term memory (LSTM) neural network to mine time series data, the method of wavelet transform (WT) was adopted at the same time, which refines the high-frequency components, and improves the forecasting accuracy of the day-ahead power load with the help of the next day's temperature and relative humidity forecast information. The results show that the proposed WT-LSTM method has a good prediction effect, and its two-day root mean square errors are 185.56 and 179.56 respectively, prediction accuracies are 61.48% and 12.51% higher than the simple LSTM neural network.

**Key words:** electric load forecasting; cloud platform; long short-term memory (LSTM) neural networks; wavelet transform (WT)

随着国家对“能源革命”的大力推进,终端用能环节的价值日益凸显<sup>[1]</sup>。一方面,提高各类能耗数据采集的准确性和安全性,确保数据采集和

传输装置的易部署性,做好数据的治理和分类存储工作,是提高电负荷预测准确性以及大幅提升其他数据利用环节工作效率的基础和重要保

**基金项目:**国网山东省电力公司科技项目(520617200001)

**作者简介:**潘广旭(1983—),男,本科,工程师,Email:7508835@qq.com

障<sup>[2]</sup>;另一方面,改进预测算法,提高电力负荷预测的准确性有利于能源企业优化资源配置<sup>[3-5]</sup>,有利于引导客户科学用能,帮助客户增效降本。

在电力负荷预测方面,文献[6]提出了一种基于改进BP神经网络的短期电力负荷预测方法,该方法为了提高传统BP神经网络预测精度,引入了猫群算法(cat swarm optimization, CSO)优化BP神经网络的权值或阈值;文献[7]采用专家系统法进行负荷预测,专家系统由于汇集了较为全面的专家知识和经验,能考虑更多种影响因素,故利用该方法预测更容易获得准确的结论;文献[8]提出了一种基于改进卡尔曼滤波的短期负荷预测方法,该方法既保持了卡尔曼滤波算法收敛速度快的优点,又引入了修正因子考虑电力负荷变化的周期性等规律,提高了预测精度;文献[9]提出了一种基于深度神经网络的中期电力负荷预测方法;文献[10]提出了一种基于自适应深度信念网络的变电站负荷预测方法,这两类均属于神经网络预测技术,该预测方法最大的优点是能够模拟人脑处理事件,具备信息记忆、自主学习、知识推理和优化计算等突出特点;文献[11]提出了一种基于改进粒子群优化长短期记忆(long short-term memory network, LSTM)网络的短期电力负荷预测方法,利用柯西变异粒子群算法寻找最优参数,克服了LSTM网络参数选取难的问题,在一定程度上提高了预测精度;文献[12]根据负荷特性考虑温度影响,通过对当日平均温度和该时刻下一日预测温度引入隶属度概念进行模糊化处理,从而减小室外温度变化对负荷预测精度的影响;文献[13]提出了一种基于深度长短期记忆神经网络的短期负荷预测方法,该方法克服了传统LSTM神经网络难以处理大量负荷数据的缺点,同时充分考虑了电力负荷的非线性特性并深度挖掘了负荷在时间序列方面的信息,确保模型在经历长时间离线训练的过程中不会陷入局部最优困扰;文献[14]提出了一种基于灰色投影改进随机森林算法的电力系统短期负荷预测方法,该方法主体部分采用随机森林算法构造电力负荷预测模型,同时引入灰色投影原理改进灰色关联相似日选取算法,从而提高预测精度。

上述用于电力负荷预测的深度神经网络模型缺乏对原始信号的降噪处理,未能对时序负荷周期性进行分析,且缺乏对实际场景中气候温度、相对湿度等重要影响因素的考量。此外,上

述提到的专家系统负荷预测方法缺乏自主学习能力,无法适应突发事件和不断变化的环境条件。

针对上述负荷预测方法存在的不足,本文结合小波变换方法和LSTM算法各自优点,提出了考虑负荷周期性、下一日温度和相对湿度的电力负荷预测方法。

首先利用小波变换捕捉和分析微小信号以及信号的细节部分,且对异常信号非常灵敏,能够较好地处理突变信号,在保证原始信号特点的同时实现降噪处理,然后考虑负荷的周期性、下一日温度和相对湿度,将分量信号送入LSTM网络进行预测,充分发挥小波变换和LSTM算法的各自优点,且充分考虑实际场景中存在的影响因素,从而提升日前电负荷预测精度。利用实际建筑电力负荷数据进行实验,结果表明本文所提预测方法比传统的预测方法精度高,同时成功将先进算法应用至开发云平台上,体现了算法策略与平台架构的有效结合。

## 1 基于云平台的数据管理系统

作为预测系统的数据源和载体,本文提出的基于阿里云平台数据管理系统包括从数据采集、数据治理到数据存储、数据应用再到结果展示的一整套工艺流程。该数据管理系统架构图如图1所示。该系统可分为三层,自下而上分别为:感知层、应用层和展现层。

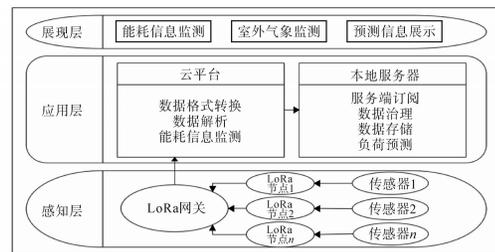


图1 数据管理系统架构图

Fig.1 Architecture diagram of data management system

感知层是数据管理系统的基础,是指用来感知各种事物的、可扩展的网络<sup>[15-17]</sup>。该层主要依靠各种传感器来采集数据,然后通过无线传输的方式将数据上传至云平台。本系统选用LoRa自组网无线通信方案。

作为负荷预测系统的核心,应用层也具备服务端订阅、数据治理、数据存储、能耗监测等一系列功能。为满足预测所需数据源间隔标准需求,利用插值法对实时上传数据自动查缺补漏,为负荷预测系统提供数据保障,最终于本地服务器完

成运行且传输至展现层。

展现层是整个数据管理系统与客户的交互界面,包括能耗信息监测、室外气象监测和预测信息展示,界面效果如图2所示。

建筑内环境监测	电力负荷预测监测	建筑物外环境监测
区域温度实时显示	区域总用电负荷 日前预测信息 实时显示	建筑物外温度 实时显示
区域湿度实时显示		建筑物外湿度 实时显示
区域各类设备用电量 实时对比显示		建筑物外雨量 实时显示
区域总用电量 实时显示	预测精度统计 信息显示	建筑物外光照度 实时显示

图2 智慧云平台用户界面

Fig.2 User interface of smart cloud platform

## 2 日前负荷预测理论与建模

### 2.1 负荷预测理论基础

#### 2.1.1 小波分析

小波分析算法是一种时域-频域的分析方法,小波变换的基本思想来源于傅里叶变换<sup>[18-19]</sup>。其在保留了傅里叶变换优点的基础上,又具有很多独特的优点<sup>[20]</sup>。例如,小波变换克服了短时傅里叶变换采样步长不变的缺点,可以根据信号源频率的大小来自主调节采样频率,故其非常适合捕捉和分析微小信号以及信号的细节部分,对异常信号非常灵敏,能够较好地处理突变信号、提高预测精度。设 $\psi(x)$ 是一个平方可积函数,则有:

1)连续小波函数结果的定义式为

$$\varphi(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t)\psi\left(\frac{t-b}{a}\right) dt \quad (1)$$

式中: $a$ 为比例因子; $b$ 为移位因子; $f(t)$ 为指原时域的信号; $t$ 为时间。

2)小波函数的容许性条件为

$$C_\psi = \int_0^{+\infty} \psi(\omega) \frac{d\omega}{\omega} < \infty \quad (2)$$

式中: $\psi(\omega)$ 为小波母函数 $\psi(x)$ 的傅里叶变换。

在满足小波函数容许性条件时,称 $\psi(x)$ 为一个基本小波或者小波母函数。

#### 2.1.2 LSTM算法理论基础

长短期记忆神经网络(LSTM)是一种特殊的递归神经网络(recurrent neural network, RNNs),它包括三个门,分别为输入门、输出门和遗忘门<sup>[21-23]</sup>。LSTM网络的模型结构示意图如图3所示。

根据LSTM网络的模型结构示意图,遗忘门的运算过程是首先取前一神经元的输出结果 $h_{t-1}$ 和本神经元的输入 $x_t$ 进行计算,然后输出一个范

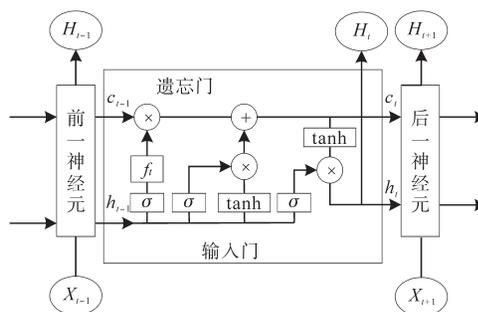


图3 LSTM网络模型结构示意图

Fig.3 Structure diagram of LSTM network model

围为[0,1]的系数 $f_t$ ,运算公式为

$$f_t = \sigma(\mathbf{W}_f[h_{t-1}, x_t] + b_f) \quad (3)$$

式中: $f_t$ 为遗忘门限; $\sigma()$ 为激活函数; $\mathbf{W}_f$ 为遗忘门权重矩阵; $h_{t-1}$ 为前一神经元的输出; $x_t$ 为本神经元的输入; $b_f$ 为遗忘门偏差参数。

如果输出系数为0,则表示本神经元完全遗忘上一细胞状态;如果输出系数为1,则表示本神经元对上一细胞状态完全记忆。该系数乘以上一细胞状态 $c_{t-1}$ ,即为输出结果。遗忘门保证了LSTM网络的长期记忆性。

输入门的运算过程类似于遗忘门,输出一个范围为[0,1]的系数 $i_t$ ,运算公式为

$$i_t = \sigma(\mathbf{W}_i[h_{t-1}, x_t] + b_i) \quad (4)$$

式中: $i_t$ 为输入门限; $\mathbf{W}_i$ 为输入门权重矩阵; $h_{t-1}$ 为前一神经元的输出; $b_i$ 为输入门偏差参数。

然后根据下式即可得到当前 $t$ 时刻细胞状态 $c_t$ :

$$c_t = f_t c_{t-1} + i_t \otimes c_t \quad (5)$$

式中: $c_{t-1}$ 为 $t-1$ 时刻的细胞状态; $i_t$ 为输入门限; $\otimes$ 表示标量乘法。

最后,根据下式得到输出门得到 $o_t$ :

$$o_t = \sigma(\mathbf{W}_o[h_{t-1}, x_t] + b_o) \quad (6)$$

然后与经过一层tanh运算得出的 $c_t$ 相乘,得最终输出 $h_t$ 如下:

$$h_t = \sigma_t \tanh(c_t) \quad (7)$$

#### 2.1.3 注意力机制

注意力机制源于对人类视觉的研究,能够突出重点而忽略其他不重要的因素。利用注意力机制进行数据处理,可以快速筛选出高价值的信息,从而大幅度提高数据处理的效率和准确性<sup>[24]</sup>。注意力机制的核心内容就是为所有元素计算权重参数,其运算过程如图4所示。其中, $K_i$ ( $i \in [1, \dots, n]$ )表示输入信息中键值对的注意力分布, $Q$ 为给定目标中的某个元素,通过计算 $K_i$ 和 $Q$ 的相似性得到 $a_i$ ,并进行归一化处理得到权重参数

$b_i, b_i$ 与输入信息中的控制向量  $value_i$  分别对应相乘再相加,即得注意力值。

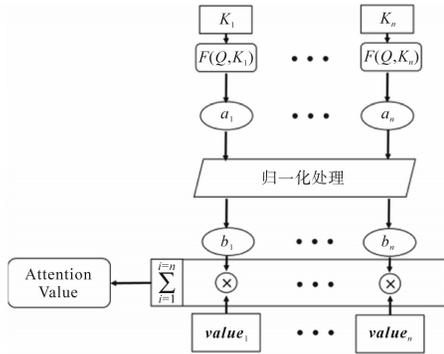


图4 注意力机制计算原理

Fig.4 The theory of attention mechanism

## 2.2 日前负荷预测模型介绍

### 2.2.1 特性分析

无论是居民社区用电还是商业、办公用电,其电功率作为预测模型的输入信号,具有很强的周期性。其与用户行为活动的周期性相关,例如商业建筑在工作日的用能相对较高,而休息日相对较低。负荷波动除受人为行为因素影响外,气候环境对建筑用能同样具有较强影响,当室外温度、相对湿度过大并且偏离人体舒适度时,建筑用电量明显上升,表现为与偏离人体舒适度程度关联性较强。负荷变化与温度、相对湿度之间不是单一的线性关系,具有强耦合、非线性的特点,因此单一的特性分析无法满足负荷预测所需精度要求,需借助 LSTM 网络完成以上特征向量对历史负荷趋势的反馈记忆与模型建立工作。

### 2.2.2 WT-LSTM 模型结构设计与分析

为解决商业建筑负荷日前预测过程中精度问题,本文提出了一种基于 WT-LSTM 的预测模型。首先通过 db2 小波变换对原始负荷粗糙数据分解为低频信号 a 与其他两个高频信号  $d_1$  和  $d_2$ 。其中低频信号 a 能够反映用能负荷的大致趋势,高频信号  $d_1$  和  $d_2$  则能具体表征负荷趋势的突变情况。借助 db2 小波变换可协助 LSTM 网络完成对不同信号之间的差异性辨识,从而有效解决单一 LSTM 网络挖掘信息特性不充足的情况。

基于上述影响因素分析与负荷小波变换结果,分别建立 3 个 WT-LSTM 日前预测模型,如表 1 所示,其中, a 模型输入分别为下一日天气预报的温度与湿度值、当天实际负荷经小波变换后的低频分量 a,输出为下一日负荷低频分量 a;  $d_1$  与  $d_2$  模型的输入与输出同理分别对应各自高频分量。因 LSTM 网络对输入形式要求(批次、时间步长、变量

维度),考虑其数据大小确定输入形式为(30,24,3)或(30,24,1),输出形式为(30,24,1)。其中模型 a 共有 3 个 LSTM 层和 1 个 Dense 层,各层的神经元个数依次为 60,40,30 和 30,采用了 Adam 优化器并使用均方误差作为优化指标,最后通过设置摒弃率来避免数据过拟合,确定的 LSTM 隐含层最优参数如表 2 所示。

表 1 模型输入输出表

Tab.1 The input and output of the LSTM model

模型	输入	输出
WT-LSTM(a)	下一日温度预报值、 下一日相对湿度预报值、 当日负荷趋势低频分量 a	下一日负荷低频分量 a
WT-LSTM( $d_1$ )	当日负荷趋势高频分量 $d_1$ 下一日负荷高频分量 $d_1$	当日负荷趋势高频分量 $d_1$
WT-LSTM( $d_2$ )	当日负荷趋势高频分量 $d_2$ 下一日负荷高频分量 $d_2$	当日负荷趋势高频分量 $d_2$

表 2 LSTM 隐含层最优模型参数

Tab.2 Optimal parameters used for the LSTM

模型	学习率	优化器	个数和神经元数		摒弃率
			LSTM 层	Dense 层	
LSTM(a)	0.010	Adam	3(60,40,30)	1(30)	0.2
LSTM( $d_1$ )	0.015	Adam	2(10,10)	2(70,80)	0.1
LSTM( $d_2$ )	0.015	Adam	3(10,20,20)	1(80)	0.2

WT-LSTM 网络整体模型框架如图 5 所示,原始电负荷作为整个系统的输入首先需对输入信号进行小波分解,然后将分解后的信号分量输入到 LSTM 网络分别预测得到结果,而后通过注意力机制模型提升数据处理效率,最后对分量预测结果进行重组。

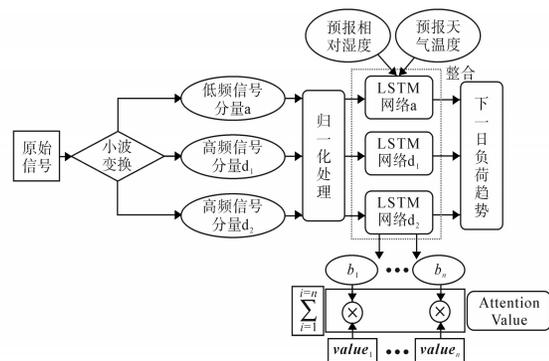


图 5 WT-LSTM 网络模型结构图

Fig.5 Structure diagram of WT-LSTM

具体工作过程如下:根据带噪声的原始信号数据特征选择恰当的小波函数;利用多种小波函数对原始信号进行分解,输出负荷低频分量 a 与高频分量  $d_1, d_2$ ;对小波分解输出的信号分量进行归一化处理得到当日电负荷趋势;将归一化之后的当日电功率信号输入 LSTM 网络,同时考虑下一日天气温度和相对湿度预报信息,经过 LSTM

网络的输入层、隐藏层和输出层的运算,得到三个信号分量的预测值;对三个信号分量预测值相加得到重组预测结果。最终通过注意力机制来完成对预测模型的参数的高度筛选。

### 2.3 评价指标与标准化处理

为了评价传统预测方法以及本文所提方法预测建筑日前电力负荷的准确性,引入均方根误差 *RMSE* 如下:

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (L_t - P_t)^2} \quad (8)$$

式中:  $L_t$  为电力负荷的实际测量值;  $P_t$  为电力负荷的预测值;  $N$  为每日测量次数。

在利用 LSTM 神经网络进行电力负荷预测之前,为了提高预测的精度和速度,引入归一化处理函数:

$$Y_n = \frac{Y_n - Y_{\min}}{Y_{\max} - Y_{\min}} \quad (9)$$

式中:  $Y_n$  为经过小波变换处理过的信号;  $Y_{\max}$ ,  $Y_{\min}$  分别为该输入信号的最大值和最小值。

## 3 算例结果分析

原始信号与经小波变换分解之后的结果如图 6 所示。从图中容易看出,原始电负荷呈现明显的周期性,每周工作日(周一至周五)电功率峰值和平均值都大于休息日(周六至周日)。此外,利用小波分解变换将原始电负荷信号按照三个不同的采样频率进行分解得到低频分量 a、高频

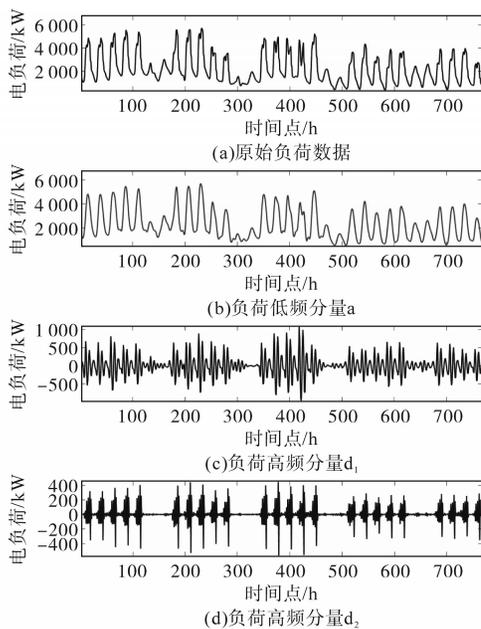


图6 小波分解变换结果

Fig.6 Results of wavelet decomposition transformation

分量  $d_1$  和  $d_2$ 。对比分量信号和原始信号可知,小波变换在保持了原始信号特征的同时,可以有效滤除噪声干扰,有利于提高预测精度。

图 7 为分量预测结果和预测绝对误差情况。一方面,对三种分量的预测在趋势上能够很好地跟踪真实曲线的变化;另一方面,随着小波变换分量的精细化程度不断提高,预测误差不断减小。对于 a 分量,最大误差达到 322 kW,  $d_1$  分量最大误差为 142 kW,而  $d_2$  分量的最大误差仅为 105 kW。

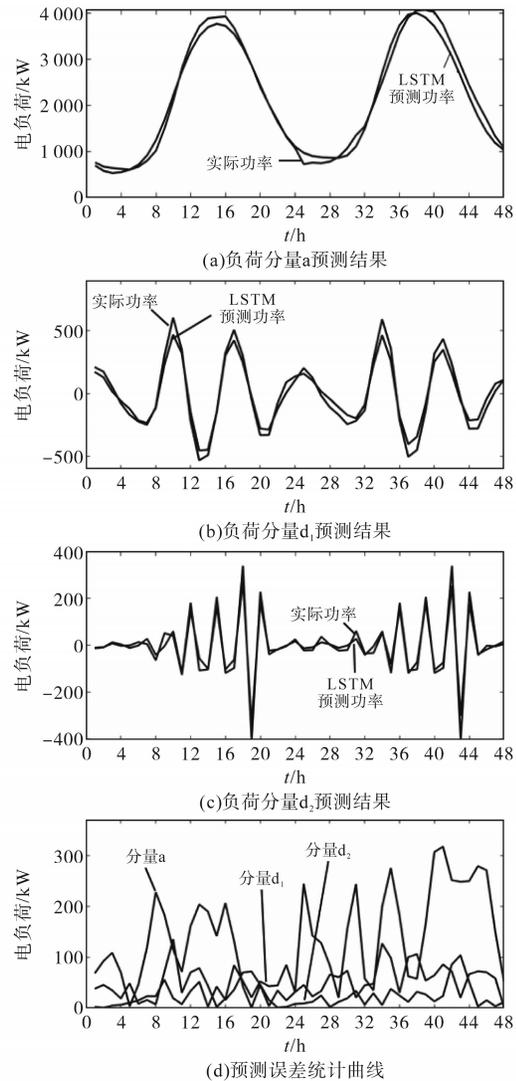


图7 分量预测结果及预测误差

Fig.7 The component prediction results and prediction errors

图 8 是实际负荷、单一 LSTM 预测、WT-LSTM 预测三者之间的对比情况。可以看出,WT-LSTM 预测曲线比单一 LSTM 预测曲线更能反映实际负荷的细节变化,例如在 14 h 左右,实际负荷有先下降后上升的趋势,WT-LSTM 预测算法很好地将该趋势反映出来,而单一 LSTM 预测则无法反映该细节变化。此外,WT-LSTM 预测比

单一 LSTM 预测精度更高,根据上述提到的均方根误差( $RMSE$ )计算式(8),第1日的单一 LSTM 神经网络预测  $RSME$  值为 481.71,本文所提预测方法  $RSME$  值为 185.56,预测准确度提高了 61.48%;第2日的单一 LSTM 神经网络预测  $RMSE$  值为 205.23,本文所提预测方法  $RMSE$  值为 179.56,预测准确度提高了 12.51%。

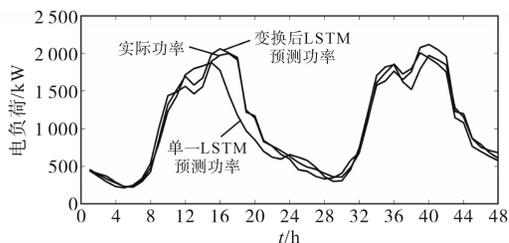


图8 基于LSTM的小波重组负荷预测结果

Fig.8 The prediction results of LSTM based wavelet recombination load

## 4 结论

针对传统电力负荷预测方法单一、考虑影响因素不全面、预测精度低以及底层数据资源传输和治理方面的问题,本文首先搭建了基于智慧云平台的数据管理系统,在确保数据资源稳定、可靠的基础上展开电力负荷预测。在电力负荷预测方面,本文结合了小波变换和 LSTM 神经网络算法的优点,同时考虑了负荷固有周期性、下一日温度、相对湿度预报信息,有效减少了系统误差、噪声以及环境因素的影响,达到了理想的预测精度。最后,本文做了客户端界面开发,能够将实时的能耗信息和预测信息展示出来供客户利用。

### 参考文献

- [1] 朱静宜. 基于物联网技术的校园建筑能耗智慧监控平台设计[J]. 物联网技术, 2020, 10(8): 39-41.  
Zhu Jingyi. Design of a smart monitoring platform for campus building energy consumption based on the Internet of Things technology[J]. Internet of Things Technology, 2020, 10(8): 39-41.
- [2] 汤奕, 张宏. 能源互联网下的智慧建筑与智慧园区[J]. 供用电, 2020, 37(5): 1-2.  
Tang Yi, Zhang Hong. Smart buildings and smart parks under the energy Internet[J]. Power Supply, 2020, 37(5): 1-2.
- [3] 江月山. 智能建筑物联网技术的体系构架[J]. 智能建筑, 2014, 172(12): 38-40.  
Jiang Yueshan. System architecture of intelligent building networking technology[J]. Intelligent Building, 2014, 172(12): 38-40.
- [4] 高婷, 陈子卓. 论基于模块化建筑物联网的架构[J]. 信息记录材料, 2022, 20(2): 65-66.  
Gao Ting, Chen Zizhuo. On the architecture based on modular building networking[J]. Information Recording Materials, 2022, 20(2): 65-66.
- [5] Dadashi-Rad M H, Ghasemi-Marzbali A, Ahangar R A. Modeling and planning of smart buildings energy in power system considering demand response[J]. Energy, 2020, 213(3): 118770.
- [6] 王克杰, 张瑞. 基于改进 BP 神经网络的短期电力负荷预测方法研究[J]. 电测与仪表, 2019, 56(24): 115-121.  
Wang Kejie, Zhang Rui. Research on short-term power load forecasting method based on improved BP neural network[J]. Electrical Measurement & Instrumentation, 2019, 56(24): 115-121.
- [7] Lahouar A, Ben Hadj Slama J. Day-ahead load forecast using random forest and expert input selection[J]. Energy Conversion & Management[J]. 2015, 103: 1040-1051.
- [8] 刘鑫, 滕欢, 官毓斌, 等. 基于改进卡尔曼滤波算法的短期负荷预测[J]. 电测与仪表, 2019, 56(3): 42-46.  
Liu Xin, Teng Huan, Gong Yubin, et al. Short-term load forecasting based on improved Kalman filter algorithm[J]. Electrical Measurement & Instrumentation, 2019, 56(3): 42-46.
- [9] 王军. 基于深度神经网络的中期电力负荷预测[J]. 重庆工商大学学报(自然科学版), 2018, 35(6): 17-21.  
Wang Jun. Mid-term power load forecasting based on deep neural network[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2018, 35(6): 17-21.
- [10] 杨智宇, 刘俊勇, 刘友波, 等. 基于自适应深度信念网络的变电站负荷预测[J]. 中国电机工程学报, 2019, 39(14): 4049-4061.  
Yang Zhiyu, Liu Junyong, Liu Youbo, et al. Load forecasting of substation based on adaptive deep belief network[J]. Proceedings of the CSEE, 2019, 39(14): 4049-4061.
- [11] 程换新, 黄震. 基于改进 PSO 优化 RNN 的短期电力负荷预测模型[J]. 电子测量技术, 2019, 42(20): 100-104.  
Cheng Huanxin, Huang Zhen. Short-term power load forecasting model based on improved PSO and optimized RNN[J]. Electronic Measurement Technology, 2019, 42(20): 100-104.
- [12] 郑瑞骁, 张妹, 肖先勇, 等. 考虑温度模糊化的多层长短期记忆神经网络短期负荷预测[J]. 电力自动化设备, 2020, 40(10): 181-186.  
Zheng Ruixiao, Zhang Shu, Xiao Xianyong, et al. Multi-layer long and short-term memory neural network short-term load forecasting considering temperature fuzzification[J]. Electric Power Automation Equipment, 2020, 40(10): 181-186.
- [13] 王激华, 仇钧, 方云辉, 等. 基于深度长短期记忆神经网络的短期负荷预测[J]. 广东电力, 2020, 33(8): 62-68.  
Wang Jihua, Qiu Jun, Fang Yunhui, et al. Short-term load forecasting based on deep long and short-term memory neural network[J]. Guangdong Electric Power, 2020, 33(8): 62-68.
- [14] 吴潇雨, 和敬涵, 张沛, 等. 基于灰色投影改进随机森林算法

- 的电力系统短期负荷预测[J]. 电力系统自动化, 2015, 39(12): 50-55.
- Wu Xiaoyu, He Jinghan, Zhang Pei, *et al.* Power system short-term load forecasting based on gray projection improved random forest algorithm[J]. Automation of Electric Power Systems, 2015, 39(12): 50-55.
- [15] 蔡友宏. 基于NB-IoT和OneNet云平台的环境监测系统[J]. 电子技术与软件工程, 2018(24): 51-52.
- Cai Youhong. Environmental monitoring system based on NB-IoT and OneNet cloud platform[J]. Electronic Technology and Software Engineering, 2018(24): 51-52.
- [16] 李铭轩. 云平台虚拟网络监控技术及应用场景分析[J]. 电信技术, 2018(12): 5-7.
- Li Mingxuan. Cloud platform virtual network monitoring technology and application scenario analysis[J]. Telecommunications Technology, 2018(12): 5-7.
- [17] 孙洁, 王兴楠, 孙晔, 等. 基于PLC的工业云平台控制系统设计[J]. 电气传动, 2020, 50(7): 71-75.
- Sun Jie, Wang Xingnan, Sun Ye, *et al.* Design of industrial cloud platform control system based on PLC[J]. Electric Drive, 2020, 50(7): 71-75.
- [18] 崔芮华, 胡文达, 耿丽恺. 基于小波重构信号奇异点的航空故障电弧检测[J]. 电气传动, 2018, 48(6): 69-72.
- Cui Ruihua, Hu Wenda, Geng Likai. Aviation arc fault detection based on wavelet reconstruction signal singularity[J]. Electric Drive, 2018, 48(6): 69-72.
- [19] 杨丽薇, 高晓清, 蒋俊霞, 等. 基于小波变换与神经网络的光伏电站短期功率预测[J]. 太阳能学报, 2020, 41(7): 152-157.
- Yang Liwei, Gao Xiaoqing, Jiang Junxia, *et al.* Short-term power prediction of photovoltaic power station based on wavelet transform and neural network[J]. Acta Solar Energy, 2020, 41(7): 152-157.
- [20] Guo Huijun, Kou Junke. Wavelet regression estimations for negatively associated sample[J]. Applicable Analysis, 2020, 99(15): 2657-2669.
- [21] Gao M, Li J, Hong F, *et al.* Day-ahead power forecasting in a large-scale photovoltaic plant based on weather classification using LSTM[J]. Energy, 2019, 187(15): 115838.
- [22] 罗宁, 高华, 贺墨琳. 基于神经网络的电力负荷预测方法研究[J]. 自动化与仪器仪表, 2020(1): 157-160.
- Luo Ning, Gao Hua, He Molin. Research on power load forecasting method based on neural network[J]. Automation and Instrumentation, 2020(1): 157-160.
- [23] Gao M, Li J, Hong F, *et al.* Short-term forecasting of power production in a large-scale photovoltaic plant based on LSTM[J]. Applied Sciences, 2019, 9(15): 3192.
- [24] Li Jing, Jin Kan, Zhou Dalin, *et al.* Attention mechanism-based CNN for facial expression recognition[J]. Neurocomputing, 2020, 411(1): 340-350.

收稿日期: 2020-12-24

修改稿日期: 2021-02-03