

雷乾, 魏强, 郑显, 等. 基于多算法智能融合的深度学习电量预测方法研究[J]. 智能计算机与应用, 2025, 15(6): 164–170.
DOI:10.20169/j.issn.2095-2163.250625

基于多算法智能融合的深度学习电量预测方法研究

雷乾¹, 魏强¹, 郑显¹, 尹梅¹, 陈钦¹, 刘佳鑫¹, 梁小龙¹, 柏银¹, 陈春玲¹, 袁练²

(1 国网重庆市电力公司铜梁供电分公司, 重庆 402560; 2 国网重庆市电力公司潼南供电分公司, 重庆 402660)

摘要: 针对城农网结合区域用户差异性导致用电量预测误差高的问题, 采用多算法智能融合的深度学习方法构建高精度的用电量预测模型。首先, 采用时间序列分解将用户用电数据分为趋势项、季节项和周期项, 并将时序分解获取的细化特征进行相似度聚类; 随后, 基于细化后类别, 采用 TCN 构建多尺度电量预测模型, 并利用自适应非线性融合方法对不同尺度 TCN 分支的预测输出进行非线性融合; 最后, 采用鲸鱼优化算法对多尺度 TCN 输出的各时序分解项的预测值进行权值比重计算, 获取用电量最终预测结果。实验结果表明, 所提方法可有效提升差异化用户用电量的预测精准度, 实现高准确度的城农网结合区域分类别的电量预测。

关键词: 时序分解; TCN; 自适应非线性融合; 鲸鱼优化; 分类别电量预测

中图分类号: TM933

文献标志码: A

文章编号: 2095-2163(2025)06-0164-07

Research on deep learning power prediction method based on multi-algorithm intelligent fusion

LEI Qian¹, WEI Qiang¹, ZHENG Xian¹, YIN Mei¹, CHEN Qin¹, LIU Jiabin¹, LIANG Xiaolong¹, BAI Yin¹,
CHEN Chunling¹, YUAN Lian²

(1 Tongliang Power Supply Branch, State Grid Chongqing Electric Power Company, Chongqing 402560, China;
2 Tongnan Power Supply Branch, State Grid Chongqing Electric Power Company, Chongqing 402660, China)

Abstract: In order to reduce the electricity consumption prediction error of Tongliang Company's urban and rural power grid combined with regional users, and achieve the universality and rationality of model application, a deep learning method with intelligent fusion of multiple algorithms is used to build a high-precision electricity prediction model. Firstly, time series decomposition is used to divide user electricity consumption data into trend items, seasonal items and periodic items, and the refined features obtained by time series decomposition are subjected to similarity clustering. Subsequently, based on the refined categories, TCN is used to construct a multi-scale power prediction model, and the adaptive nonlinear fusion method is used to nonlinearly fuse the prediction outputs of TCN branches at different scales. Finally, the whale optimization algorithm is used to calculate the weight of the predicted value of each time series decomposition item output by the multi-scale TCN, and the weight and the predicted value are combined to obtain the final power consumption prediction result. Experimental results show that the proposed method can effectively improve the prediction accuracy of user electricity consumption and achieve high-accuracy electricity prediction for urban and rural power grids combined with regional classification.

Key words: time sequence decomposition; multi-scale TCN; adaptive nonlinear fusion; whale optimization algorithm; electricity forecast by category

0 引言

随着社会电气化水平的提升, 社会生产和居民生活的用电需求日益增加, 负荷创新高将成为常态,

尤其双碳目标的提出, 新能源出力并网的随机波动性、以及水资源的季节性, 均将导致电力系统平衡失调, 电力供需平衡难度进一步加大, 故用电量预测对于电力系统整体规划以及资源配置方面均具有十分

作者简介: 魏强 (1973—), 男, 学士, 政工师, 主要研究方向: 铜梁供电公司的电量电费统计、分析和预测; 郑显 (1970—), 男, 学士, 工程师, 主要研究方向: 营业和电费电价研究。

通信作者: 雷乾 (1989—), 男, 学士, 工程师, 主要研究方向: 电量预测和负荷预测等。Email: 1219793415@qq.com。

收稿日期: 2023-11-13

哈尔滨工业大学主办 ◆ 专题设计与应用

重要的意义。在研究不同用户用电属性的基础上进行用电量预测,能够大力推动电力系统的发展^[1]。

然而用户用电量预测受很多因素的影响,近年来,诸多学术机构及学者对该问题进行了大量研究。针对企业现存的月度用电预测存在样本数量较少和数据精度不足等问题,文献[2]基于偏最小二乘(PLS)法构建出可用于企业用电量预测的模型,解决了所获取数据之间相关性较高的问题,并通过数据仿真验证了模型的有效性和准确性。在电能预测方面,深度神经网络性能表现较差。为了改变现状,文献[3]提出了基于正弦粒子群优化神经元数量的深度神经网络算法,通过改进粒子群算法惯性权重和进行变异操作,进而优化深度神经网络隐藏层的神经元参数。文献[4]为解决传统区域用电量预测方法存在的预测能力差的问题,提出了基于ARIMA模型的区域用电量预测方法。首先通过ARIMA模型对用电量数据进行平稳性检测,然后利用最小二乘估计方法对用电量参数进行估算,最后结合线性神经网络完成区域用电量预测模型的构建,从而实现区域用电量的预测。文献[5]为实现精准的居民用电量短期预测,采用3次指数平滑法构建用电量预测模型,实现居民未来3天用电量的低误差预测,并结合气象数据进行居民用电气象敏感度分析。

上述用电量预测方法往往针对单一类型用户用电量的预测,难以实现模型应用的普适性,且随着时间推移用户用电特性往往存在漂移,深度学习模型实现适用性调整存在调参困难的问题。针对当前研究现状及存在的问题,本文基于用户历史用电数据对不同类别用户的用电量进行估算,采用分解-预测-重构的方式,通过智能融合多尺度算法增强用电量估算的准确度与合理性,并可根据时序漂移量进行动态调整。本文所提用电量预测方法的贡献如下:

(1)针对当前用户类别分类未考虑不同用户的用电行为特性,导致建模预测精准度低的问题,采用时序分解算法对用户用电数据进行特征分解,并在用户聚类时充分考虑用户用电体量、各变量对其用电量的影响因素,从而提高类内相似度。

(2)针对现有用电量预测算法普遍存在预测精度低的问题,基于多尺度时序特征TCN构建用电量预测模型,通过设置满足不同分解特征的因果膨胀卷积层,构建多尺度TCN预测模型,从而更好地拟

合不同时间尺度下用电序列的时序特征,提高用电量预测的准确性。

(3)随着时间推移用户用电特性往往存在漂移,针对现有深度学习模型难以实现适用性调整的问题,本文利用鲸鱼优化算法,对多尺度TCN输出的各时序分解项的预测值进行权值分配计算,获取用电量最终预测结果,从而提高电量预测模型的适用性。

1 整体过程描述

本文基于城农网结合区域各用户的历史用电数据,对各类别用户进行用电量预测,并能随着时间推移实现电量预估模型动态调整。构建过程流程如图1所示。为增强预测模型的准确度与合理性,采用TCN构建多尺度电量预测模型,整体构建过程如下。

针对获取的城农网结合区域各用户的历史用电样本数据,将用户用电量数据按时间序列分解为长期趋势项、周期项、季节项和噪音项,从而细化用户用电特征,并在城农网结合区域用户基本分类基础上,在类别内根据时序分解后获取的用电量细化特征,采用k均值聚类算法进一步细化用户分类,提升类内用户的相似度;随后,基于不同的细化分类,将得到的输入矩阵并行送入具有不同尺度卷积核的TCN中进行多尺度时序特征提取和预测;最后,采用鲸鱼优化算法对多尺度TCN输出的各时序分解项的预测值进行权值计算,获取最终用电量预测结果,实现高准确度的城农网结合区域分类别的电量预测模型。

2 用电量预测过程

2.1 时间序列分解提取用电特征

当前的城农网结合区域的类别主要分为:保底供电(居民、农业)、代理10 kV以下工商业用户、代理10 kV及以上工商业用户(代理购电中大工业客户、代理购电一般工商业客户)、直接参与市场用户(市场化大工业用户用电、市场化一般工商业及其他用电)分类别分电压等级。

由于用户用电量数据具有典型的时间序列特性,即存在长期趋势、周期变动、季节变动和不规则变动等因素,故本文基于历史用户用电量数据样本,从长期趋势项、周期项、季节项和噪音项四个角度归纳不同用户用电量数据的变化特征。




图 1 构建过程流程图
Fig. 1 Flow chart of construction process

基于用户用电量样本数据,本文采用加法与乘法混合分解模型^[6]进行时序数据分解:

$$X_t = (T_t + C_t) \cdot S_{t-m} \cdot I_{t-m} \tag{1}$$

其中, X_t 表示用户在第 t 日的日用电量数据; T_t 表示用户日用电量在第 t 日呈现的长期趋势特征,具有持续向上、或持续向下、或平稳的趋势性; S_{t-m} 为季节项,表示用户在第 t 日的日用电量受季节因素影响所形成的一种幅值相对固定的周期性波动; C_t 表示周期项,是用户日用电量在第 t 日受用户日常行为影响形成的日周期起伏不定波动; I_{t-m} 表示噪音项,是受各种偶然性因素影响所引起变动; $t-m$ 表示第 t 日属于第 m 季节,其 S 和 I 的取值为日期 t 所处季节 m 的值。在此基础上,展开研究分析如下。

(1) 对用户用电量时序数据的各个时序特征进行求解,首先季节项 S 与噪音项 I 的求解过程如下:

$$M_m = \frac{X_m + X_{m-1} + \cdots + X_{m+N-1}}{N} \tag{2}$$

$$SI_m = X_m / M_m \tag{3}$$

其中, N 表示以年为周期的用户季节用电量,以某省气候特征为例, N 取 4; X_m 表示用户在第 m 个季节的用电量数据。

然后计算季节指数 r , 相当于计算以年为周期的移动平均值,并从几年中挖掘一个季节的用户用电量数据规律:

$$r_m = \frac{\sum_{j=1}^N SI_m^{(j)}}{T}, m = 1, 2, \cdots, N \tag{4}$$

其中, T 表示获取样本数据的年周期数; $SI_m^{(j)}$ 相当于第 j 年的第 m 个季节的季节项与噪音项乘积。

对 r 进行修正,定义修正后的季节指数为 R ,此时 R 代表了季节项 S 和噪音项 I 的求解值:

$$R_m = r_m / \left(\frac{\sum_{m=1}^N r_m}{N} \right) \tag{5}$$

(2)长期趋势项 T 的求解过程。根据获取到的用户日用电量数据 x_t , 为捕获用户日用电量与时间的关系, 本文采用 ARMA 模型拟合, 定义趋势拟合数据 T_t 如下:

$$T_t = a_0 + \sum_{i=1}^g a_i T_{t-i} + \sum_{i=1}^h b_i \varepsilon_{t-i} + \varepsilon_t \quad (6)$$

其中, $\{T_t\} (t = 1, 2, 3, \dots)$ 表示用户日用电量趋势时间序列; g 和 h 分别表示自回归模型和移动平均模型的阶数; a_i 和 b_i 表示模型待估系数; ε_t 表示均值为 0, 方差为 σ^2 的正态白噪声过程。

对用户日用电量数据进行分析后, 通过差分方法对其进行平稳化处理。本文中, 长期趋势项 T 满足平稳性要求。当建模时, 先根据用电量数据样本序列自相关系数的截尾性和偏自相关系数的拖尾性设定模型阶数初值, 并按照 AIC 最小作为标准确定模型的各个参数, 待所有参数均固定后, 对目标序列进行拟合检验, 最后输出长期趋势项 T 。

(3)求解周期项 C 的过程。首先剔除了季节项 S 和噪音项 I 对用户日用电量数据 x_t 的影响量, 即:

$$C'_t = \frac{x_t}{R_{t \sim m}} \quad (7)$$

其中, $R_{t \sim m}$ 表示第 t 日处于 m 季节受季节项 S 和噪音项 I 的共同影响值。

随后, 剔除趋势项 T 对用户日用电量数据 x_t 的影响量, 获取用户在第 t 日的周期项 C_t :

$$C_t = C'_t - T_t \quad (8)$$

基于时序分解得到各用户用电量细粒度属性特征, 在城农网结合区域基本分类的基础上, 在用户类别内, 采用 k 均值算法^[7] 进行用户相似度聚类, 实现更加精准的相似用户分类。

2.2 基于 TCN 的多尺度电量预测模型

由于单个 TCN 对不同时间尺度的信息提取能力依然存在一定的限制, 因此本文在单一 TCN 模型的基础上提出一种多尺度 TCN 算法。基于聚类获取的细分用户类别, 采用多尺度 TCN 模块对城农网结合区域多元用户用电负荷序列进行多时间尺度特征信息的挖掘。

TCN 主要包含多个带有残差连接的残差模块, 且每个残差模块由多个因果膨胀卷积层构成。多尺度 TCN 模块由 3 个不同卷积核大小的 TCN 并行组成, 其中大尺度卷积核的 TCN 用来捕捉长周期局部信息, 小尺度卷积核的 TCN 用来捕捉短周期局部信息, 每个 TCN 都包含 2 个残差模块。

因果膨胀卷积包括因果卷积和膨胀卷积两部

分。其中, 因果卷积解决了传统卷积在时间序列预测任务上存在的“信息泄露”问题, 即在预测当前时刻信息时只能利用历史时刻的信息, 而不能利用未来时刻的信息。而膨胀卷积解决了传统卷积感受野具有局限性的问题, 通过引入膨胀率 d 来控制输入数据的采样间隔, 使得网络能够灵活调整其感受野的大小。

对于卷积核 $f: \{f_0, f_1, \dots, f_{k-1}\}$ 和输入 $W = \{w_1, w_2, \dots, w_n\}$ 来说, 因果膨胀卷积的运算公式为:

$$F(y) = \sum_{l=0}^{k-1} f_l \cdot w_{y-(d \cdot l)} \quad (9)$$

其中, $F(y)$ 表示对输入 W 中第 y 个元素的卷积运算结果; k 表示卷积核大小; f_l 表示卷积核中的第 l 个向量; d 表示膨胀率; $w_{y-(d \cdot l)}$ 表示第 y 个元素以及 y 之前的用户历史用电数据。

残差模块通过引入残差连接跳过一个或多个隐藏层, 能够很好地解决深度学习网络由于层数的加深而带来的性能退化问题。在每层因果膨胀卷积之后加入 ReLU 激活函数层、标准化层和正则化层, 连接 2 次堆叠构成 1 个残差模块。将残差模块的数据通过全连接层进行输出, 得到各 TCN 分支的预测值。

传统的融合方法通常为简单的线性加权融合^[8-11], 本文基于自适应非线性融合方法对不同尺度 TCN 分支的预测输出进行非线性融合, 其主要思想是将权重矩阵进行非线性化操作, 使得总体模型能够非线性地融合 3 个不同尺度 TCN 分支的输出, 以此得到比单分支更好的预测结果。

具体来说, 假设第 p 个 TCN 分支的输出结果为 $v_p = \{v_{p1}, \dots, v_{pq}, \dots, v_{pt}\}$, 其中 v_{pq} 表示输出结果中第 q 个时间步的向量, 包含各时序分解项的预测值, 这里 t 表示预测的总步长, 则 3 个不同尺度 TCN 分支的输出结果可以用矩阵 V 来表示, 具体公式如下:

$$V = \begin{pmatrix} v_1 \\ v_2 \\ v_3 \end{pmatrix} = \begin{pmatrix} v_{11} & \cdots & v_{1t} \\ \vdots & \ddots & \vdots \\ v_{31} & \cdots & v_{3t} \end{pmatrix} \quad (10)$$

相应地, 每一个时间步被分配一个权重 e_{pq} , 权重矩阵 E 可表示为:

$$E = \begin{pmatrix} e_{11} & \cdots & e_{1t} \\ \vdots & \ddots & \vdots \\ e_{31} & \cdots & e_{3t} \end{pmatrix} \quad (11)$$

接下来, 通过下式计算得出最终的融合预测结果:

$$Q = \sigma[\text{sum}(\mathbf{V} \times \text{Softmax}(\text{dropout}(\mathbf{B})))]$$

(12)

其中, Q 表示最终用电量预测结果; σ 表示 ReLU 激活函数; sum 表示将 3 个分支模型在进行非线性权重融合后相加; “ $\times$ ”表示 2 个矩阵对应位置的元素相乘; dropout 表示将 B 中元素按照给定比例随机置零,防止出现过拟合。

模型预测结果输出后,采用鲸鱼优化算法(WOA)确定不同类别中时序分解项各部分预测值的权值,其迭代公式为:

$$\mathbf{Y}_{t+1} = \mathbf{y}_{\text{rand}} - \mathbf{A} \mid \mathbf{P}\mathbf{Y}_{\text{rand}} - \mathbf{Y}_t \mid$$

(13)

$$\mathbf{A} = 2\mathbf{co} - \mathbf{c}$$

(14)

$$\mathbf{D} = 2\mathbf{o}$$

(15)

其中, $\mathbf{Y}_t$ 表示鲸鱼位置向量; $\mathbf{Y}_{\text{rand}}$ 由当前鲸鱼位置决定;随着迭代,向量 $\mathbf{c}$ 从 2 到 0 线性减小,向量 $\mathbf{o}$ 在 0~1 之间随机变动; $\mathbf{P}$ 表示由向量 $\mathbf{o}$ 确定的系数矩阵; $\mathbf{A}$ 表示由 $\mathbf{c}$ 决定的系数矩阵。

开始迭代时,由于 $\mathbf{c}$ 向量值较大, $\mid \mathbf{A} \mid$ 值将大于 1,从而保证寻求最优解的可靠范围;当 $\mid \mathbf{A} \mid$ 值小于 1 时,包围猎物的过程开始,此时的计算公式为:

$$\mathbf{Y}_{t+1} = \begin{cases} \mathbf{Y}_t^* - \mathbf{A} \mid \mathbf{P}\mathbf{Y}_t^* - \mathbf{Y}_t \mid, & \alpha < 0.5 \\ \mid \mathbf{Y}_t^* - \mathbf{Y}_t \mid \tilde{\omega}^{\tau\lambda} \cos(2\pi L) + \mathbf{Y}_t^*, & \alpha > 0.5 \end{cases}$$

(16)

其中, $\mathbf{Y}_t^*$ 表示当前最佳位置; $\tilde{\omega}$ 表示常数,用来确定鲸鱼捕猎的螺旋路径; L 表示螺旋系数; α 表示 0~1 之间的随机数。

经过鲸鱼优化算法分别获取到各时序分解项的权值参数:长期趋势项 (Y_{t+1}^1)、周期项 (Y_{t+1}^2)、季节项和噪音项 (Y_{t+1}^3),并将其权值与对应预测值合并,最后利用时序数据分解模型、即式(1) 获取最终的用户用电量预测值 X' 。对此可表示为:

$$X'_t = (Y_{t+1}^1 T'_t + Y_{t+1}^2 C'_t) \cdot Y_{t+1}^3 S'_{t-m} I'_{t-m}$$

(17)

其中, T'_t 、 C'_t 和 $S'_{t-m} I'_{t-m}$ 分别表示长期趋势项预测值、周期项预测值以及季节项和噪音项预测值。

3 实验与分析

本文以国网某公司用电信息采集系统为实验平台,依照当前细化聚类后的城农网结合区域用户类型,选取各类三分之一的用户一年(2022 年 1 月 1 日至 2022 年 12 月 31 日)的用电数据作为训练样本集,共计获取 365 178 例样本集;在每类用户样本中,各选取 1 000 个用户作为测试样本。从营销业

务应用系统中获取用户档案类数据,用电信息采集系统中获取用户用电数据,基于网页爬取获取天气及节假日数据,收集上述数据作为样本特征数据集。特征数据见表 1。

表 1 用电样本特征数据

Table 1 Electricity sample characteristic data

档案特征	用电数据特征	环境特征
户号	用电量	温度
用户类型	高峰时段	节假日

3.1 用电量预测准确性对比

选取部分测试样本集数据对本文所提方法的有效性进行测试。本部分选取测试集中 1 356 户真实用电量样本数据,将各用户某一时间节点的前 2 周的用电数据输入用户用电量预测模型中,对用户下一周的用电量进行预测,将用户用电量预测值与用户真实的用电量进行对比,从而评估本文方法预测准确性。

本文采用均方根误差(Root Mean Squared Error, $RMSE$) 和平均绝对误差百分比(Mean Absolute Percentage Error, $MAPE$) 作为用电量预测准确性评价指标,对模型的性能表现进行评估。 $RMSE$ 是预测值与真实值偏差的平方与观测次数 n 比值的平方根,可以更好地反映预测误差的实际情况。 $MAPE$ 是指将预测值与实际值之间的绝对误差转化为百分比的平均值,用于评估预测模型的准确性和误差程度。 $RMSE$ 和 $MAPE$ 的结果越小,代表预测准确性越高。其计算公式如下:

$$RMSE = \sqrt{\frac{\sum_{\beta}^Z (u_{\beta} - \hat{u}_{\beta})^2}{Z}} \times 100\%$$

(18)

$$MAPE = \frac{100\%}{Z} \sum_{\beta=1}^Z \left| \frac{u_{\beta} - \hat{u}_{\beta}}{u_{\beta}} \right|$$

(19)

其中, u_{β} 表示用户用电量真实值; $\hat{u}_{\beta}$ 表示用户用电量预测值; Z 表示测试样本集中的用户用电数据的数量。

本文选取 3 类对比方法进行用户用电量预测准确性对比,分别为集合模态经验分解(EEMD)和 BP 神经网络、随机森林算法变量选择(RF)与长短期记忆网络回归(LSTM)、粒子群算法(PSO)+支持向量机(SVM)。对此给出具体阐释如下。

(1)集合模态经验分解(EEMD)和 BP 神经网络^[12]:由以气象因子为主的多个自变量的最优组合共同来预测或估计因变量,从而实现精准用电量预

测。

(2) 随机森林算法变量选择 (RF) 与长短期记忆网络回归 (LSTM)^[13]: 利用 RF 方法获取用电量关键影响因素, 结合 LSTM 回归方法, 组建用电量预测模型, 实现用电量预测。

(3) 粒子群算法 (PSO) + 支持向量机 (SVM)^[14]: 基于 SVM 的递归特征消除特性 (RFE) 筛选个影响用电量的各个指标, 采用粒子群 (PSO) 算法根据电力应用场景构建用电量预测模型。

本文方法与其他 3 种算法的预测性能对比, 见表 2。

表 2 算法性能对比		
Table 2 Performance comparison of algorithms		%
方法	RMSE	MAPE
本文方法	35.02	7.59
EEMD 和 BP 神经网络 ^[12]	67.14	28.05
RF 变量选择和 LSTM ^[13]	72.83	35.26
PSO-SVM ^[14]	61.59	24.83

由表 2 可以看出, 本文方法相对其他类似方法, 具有明显的优势, 可准确预测出用户用电量数据。实验结果表明, 本文采用时序分解和多尺度 TCN 方法构建的电量预测模型, 可有效提升对用户电量的估算精度。

当对城农网结合区域所包含的不同用户类别分别进行用电量预测时, 对比本文预测方法与其他 3 种预测方法预测性能以及同方法的一致性。用户类别 1 代表保底供电 (居民、农业), 用户类别 2 代表代理 10 kV 以下工商业用户, 用户类别 3 代表代理 10 kV 及以上工商业用户 (代理购电中大工业客户、代理购电一般工商业客户), 用户类别 4 代表直接参与市场用户 (市场化大工业用户用电、市场化一般工商业及其他用电)。对比结果如图 2 所示。




图 2 Comparison of performance of multi category prediction algorithms

从图 2 对比结果可以看出, 本文所提方法对 4 类用户的用电量预测准确率均优于其他 3 种方法,

且对于本文方法, 4 类用户的预测误差相差不大, 均表现出了较好的预测性能。实验数据表明本文所提算法可实现分类别的精准用电量预测, 具有很好的普适性。

3.2 消融实验对比分析

为了验证本文所提基于时序分解细化用户类别、采用多尺度 TCN 算法进行用电量预测和利用鲸鱼优化算法计算各时序分解项的权值对模型预测准确率的影响, 此处以消融实验进行对比分析, 即在本文方法中, 分别为无时序分解细化聚类环节 (方法 2)、不采用多尺度 TCN 算法进行用电量预测 (方法 3) 和不利用鲸鱼优化算法优化各时序分解项的权值 (方法 4), 并将上述 3 种方法与本文方法 (方法 1) 的预估精度进行对比, 同样选择测试集样本进行测试, RMSE 和 MAPE 作为评价指标, 对比结果见表 3。

表 3 用电量预测对比		
Table 3 Comparison of electricity consumption forecasts		%
方法	RMSE	MAPE
1	10.35	2.97
2	39.28	24.17
3	45.63	36.58
4	37.64	29.05

由表 3 可以看出, 本文方法不包含时序分解细化聚类环节时, 由于长期用电量预测的一个难点就是, 不同用户的用电体量、各个影响因素对其用电量的影响是不同的, 而采用时序分解细化聚类, 提高类内用户用电量在多维度的相似度, 故可在城农网结合区域定义的用户分类基础上, 考虑用户体量、用电趋势、各个影响因素的影响度进行聚类, 从而降低了后续预测建模难度, 可有效提升用电量预测精准度。而当采用传统时序预测算法、比如 LSTM 时, 只能进行串行计算, 效率低且误差大, 本文采用多尺度 TCN 方法, 可进行并行计算, 并能通过膨胀因子扩大感受野的范围, 可实现城农网结合区域多元用户用电量数据多时间尺度的特征信息挖掘, 从而提高用电量的预测精度。方法 4 在不采用鲸鱼优化算法时, 直接进行时序分解项的合并会导致预测准确率高低的不确定性, 而本文采用后可确定不同类别中时序分解项各部分预测值的权值, 并且可在后续的预测中对于时序偏移量进行动态调整, 从而使得预测精度高且稳定。

4 结束语

本文采用时序分解算法将用户用电量数据分解

为长期趋势项、季节项、周期项和噪音项,并将其作为用户用电量细化特征进行聚类;然后基于聚类后的不同用户类别,采用多尺度 TCN 进行用户用电量预测,并基于鲸鱼优化算法(WOA)对不同类别中时序分解项各部分预测值的权值进行计算,基于权值调整各个预测值的比重,获取用电量最终预测值。通过实验验证预测模型性能,对各类别用户用电量数据的预测准确率有了明显提高。本文所提方法为多类别用电量预测提供了可靠方法,具有较高的实际应用价值,助力建设“渝电特色、国网示范”新型电力系统。

参考文献

[1] 覃晖,罗超,包忠强,等. 考虑远景约束的中长期用电量预测方法研究[J]. 电力需求侧管理,2022,24(4):59-66.

[2] 胡敏,张跃伟,高孝天. 基于偏最小二乘回归的企业用电量预测研究[J]. 电器与能效管理技术,2023(6):58-62.

[3] 蔡翔,朱莉. 改进深度神经网络的用户用电量预测方法[J]. 湖北工业大学学报,2023,38(1):15-20.

[4] 钱嫣然,何慧之,仇海英,等. 基于 ARIMA 模型的区域用电量预测方法[J]. 信息技术,2023,47(1):180-185.

[5] 姚长征,张自强,李玉杰,等. 基于大数据背景下时间序列的用

电量预测模型构建[J]. 粘接,2022,49(10):180-184.

[6] WANG Yubo, SARASWAT S K, KOMARI I J. Big data analysis using a parallel ensemble clustering architecture and an unsupervised feature selection approach[J]. Journal of King Saud University Computer and Information Sciences,2023,35(1):270-282.

[7] 尹忠东,陈俊晔,沈子伦,等. 基于 Kmeans 聚类的配网变压器绕组材质辨识算法[J]. 华北电力大学学报(自然科学版),2024,51(5):66-73.

[8] 吴佳懋,李艳,符一健. 基于粗糙集-混沌时间序列 Elman 神经网络的短期用电量预测[J]. 电力系统保护与控制,2019,47(3):29-36.

[9] 闵旭,叶青,蔡高琰. 基于残差自回归方法的短期区域用电量预测[J]. 技术经济,2019,38(6):119-124.

[10] 腾腾,赵治华. 电磁发射系统监测量预测方法[J]. 电工技术学报,2018,33(22):5233-5243.

[11] 崔佳豪,毕利. 基于混合神经网络的光伏电量预测模型的研究[J]. 电力系统保护与控制,2021,49(13):142-149.

[12] 张震,肖莺,任永建,等. 基于气象因子的 EEMD-BP 方法在电网用电量预测中的应用[J]. 南方能源建设,2024,11(1):122-132.

[13] 吴翔宇,荀超,肖芬,等. 基于 RF 变量选择与 LSTM 回归的长期用电量预测模型[J]. 电气传动,2023,53(5):71-76.

[14] 罗红郊,马晓琴,孙妍,等. 基于 RFE 特征选择的 PSO-SVM 用电量预测算法[J]. 电子设计工程,2023,31(20):172-176.