

基于聚类经验模态分解的 CNN-LSTM 超短期电力负荷预测

刘亚瑛, 赵倩

(上海电力大学 电子与信息工程学院, 上海市 杨浦区 200090)

Ultra-short-term Power Load Forecasting Based on Cluster Empirical Mode Decomposition of CNN-LSTM

LIU Yahui, ZHAO Qian

(College of Electrical Engineering, Shanghai University of Electric Power, Yangpu District, Shanghai 200090, China)

ABSTRACT: To reduce the influence of complicated environmental factors on the results of the ultra-short-term electrical load forecasting and improve the prediction precision and operation efficiency of the algorithms, this paper proposes a CNN-LSTM hybrid prediction algorithm based on the cluster empirical mode decomposition (CEMD). Firstly, this empirical mode decomposition (EMD) is used to decompose the load data into several intrinsic mode functions (IMF) and residual (Res) with the excellent smoothness and regularity. Secondly, for the sake of simplify the calculation volume of the subsequent model, the k-means clustering method is used to group and integrate the decomposed components. In the mean time, by analyzing the prediction effect of different clustering numbers, the optimal clustering tag is selected to construct the input data of the neural network. After that, the data of each group are input into the CNN-LSTM hybrid neural network, where the CNN mines the features between the data to form the feature vectors which are input into LSTM for prediction. Finally, all the forecasting results are added linearly to get the complete forecast load. Compared with the existing models, the proposed method in this paper has higher prediction accuracy through the real load test.

KEY WORDS: ultra-short-term load forecasting; CEMD; CNN; LSTM

摘要: 为了减少复杂环境因素对电力负荷超短期预测效果的影响, 提高算法的预测精度和运算效率, 该文提出一种基于聚类经验模态分解(cluster empirical mode decomposition, CEMD)的卷积神经网络和长短期记忆网络(convolutional neural network and long short term memory network, CNN-LSTM)混合预测算法。该算法首先通过经验模态分解法将负荷数据分解为平稳性好、规律性强的若干本征模态函数(intrinsic mode functions, IMF)和残差(residual, Res)。其次为了简化后续模型的计算体量, 运用 k 均值聚类方法对分解所得的各分量进行分组集成, 同时分析不同聚类数对应的预

测效果, 选取最优聚类标签构造神经网络输入数据。之后将各组数据分别输入到 CNN-LSTM 混合神经网络中, 利用 CNN 挖掘数据间的特征形成特征向量, 并将其输入到 LSTM 中进行预测。最后将所有预测结果进行线性相加得到完整预测负荷。通过在真实负荷上进行验证并与现有模型进行比较, 所提方法具有更高的预测精度。

关键词: 超短期负荷预测; 聚类经验模态分解; 卷积神经网络; 长短期记忆网络

DOI: 10.13335/j.1000-3673.pst.2021.0016

0 引言

超短期电力负荷预测可用于发电厂进行日内实时发电规划。准确的预测结果可以有效保障电力系统稳定运行, 减少发电设备的成本, 提高电网调度的效率^[1-3]。传统电力负荷预测主要用于电网调度部门指导发电企业制定发电、配电计划, 研究主要集中在供给侧, 很少对用户侧的用电行为进行分析和预测^[4]。随着电力市场的发展和分布式可再生能源的大量入网, 以工业厂房、商业中心、小区住宅为主的用电用户对可再生能源的消纳能力逐步提高, 用户侧发电在现代电网中所占比重越来越大。对于用户侧用电行为进行分析有助于提高需求侧能源管理系统的效率, 提高输发电设备的利用率^[5]。近期随着智能电网技术的不断推广以及智能电表等智能检测设备的大量投入, 为基于深度学习的用户侧电力负荷预测提供了海量和高质量的数据基础。

目前预测电力负荷的方法主要分为 2 种: 数学统计模型算法^[6-10]和机器学习算法^[11-14]。对于统计模型算法来说, 其优点是模型结构简洁, 计算量小, 预测迅速。如文献[6]针对特征量少, 数据量大的用电负荷数据运用多元线性回归算法进行

预测。文献[7]分析了不同节假日对负荷的影响,并针对不同类型的节假日建立了卡尔曼滤波预测模型。文献[8]提出了一种以指数平滑法为基础的组负荷预测模型。上述算法对于波动性小、随机性弱、时序性强的电力负荷,可以迅速获得准确的预测结果。但是对于复杂度比较高的非线性负荷数据,由于统计学算法的鲁棒性较差,难以对其进行准确的预测,而机器学习算法可以有效处理非线性问题。如文献[11]考虑了电价因素,提出了一种基于改进支持向量机的混合预测模型。该模型采用最小冗余最大相关法提取特征,利用加权灰色关联投影法选取假日历史负荷序列,最后利用支持向量机进行预测,并引用改进粒子群算法优化超参数以提高模型预测能力。文献[12]对输入特征进行分析,采用自相关函数选取最优特征,并利用最小平方支持向量机进行预测。文献[13]提出了一种由轻型梯度增强机和极限梯度增强机生成元数据,利用多层感知机计算最终预测结果的堆叠集成预测模型,克服了单一模型的固有缺陷,提高整体预测能力。但传统机器学习算法的模型参数较少,面对如今海量而复杂的电力数据,难以对蕴含在数据中的信息进行有效表达,从而无法达到理想的预测结果。

得益于人工智能领域的快速发展,近年来深度学习算法以其强大的非线性映射和自适应能力被广泛应用于电力负荷预测并取得了出色的效果。其中以递归神经网络(recurrent neural network, RNN)为基础而改进的长短期记忆网络(long short term memory network, LSTM)和门控循环单元(gated recurrent unit, GRU)网络在长时序问题的处理上贡献尤为突出。如文献[15]采用长短期记忆网络进行负荷预测,同时为了增加模型的泛化能力采用随机搜索方法进行网络参数寻优。文献[16]采用误差倒数法将 LSTM 和极限梯度提升(extreme gradient boosting, XGBoost)搭建成混合预测模型进行负荷预测。文献[17]提出了一种卷积神经网络-门控循环单元(convolutional neural network-gated recurrent unit, CNN-GRU)混合神经网络模型,文献[18]提出了一种 CNN-LSTM 混合神经网络模型,2种算法都是先利用 CNN 提取负荷特征,之后利用 GRU 或 LSTM 神经网络进行预测。这种组合算法可以更好地挖掘数据特征,大大减小了人工提取特征所引起的误差,从而提高预测精度。

相较于传统算法,深度学习算法拥有诸多优点,但其在回归预测领域的表现往往取决于输入数据的质量和数量。然而实际的电力负荷受到诸多复

杂因素的影响,如:气温、风速、日期类型等,同时随着各种储能设备和可再生分布式电源的大量连网,以及基于电价激励措施的需求侧管理政策的执行,大大增加了负荷预测的难度,这使得运用单一方法进行负荷预测难以获得准确的预测结果。为了应对外界因素的影响提高预测精度,将数据预处理技术结合现有预测模型的混合预测方法被广泛应用于电力负荷预测中。如文献[19]将预处理后的负荷数据采用改进互信息技术提取关键特征,之后利用因子条件约束玻尔兹曼机进行预测。文献[20]针对不同用户的用电数据和相关特征,通过聚类算法将特征相似的用户数据集成预测提高预测精度。文献[21]采用注意力机制,通过对影响负荷的特征分配权重而突出关键因素以提高预测精度。但上述算法都只是利用了数据的浅层特征,未对数据进行深度剖析。而负荷分解可以充分利用数据的时序特性,将负荷分解为若干分量,每个分量可以单独处理从而避免了不同时间特征之间的相互干扰。如文献[22]提出了一种基于变分模式分解、广义神经网络和重力搜索算法的进化机器学习模型,用于负荷和电价的预测。文献[23]使用小波分解法对负荷数据进行预处理之后运用神经网络进行预测,并结合蝙蝠算法和比例共轭梯度法优化网络超参数,以提高预测精度。小波变换法虽然可以分解负荷序列,但是对于分解平稳性差的序列,其选取不同的小波基函数和分解层数有不同的效果,这使得该方法具有一定先验性,增加了预测难度。而经验模态分解^[24](empirical mode decomposition, EMD)法具有自适应的特点,其依据序列自身的时间特征对数据进行分解,不需要人为预设参数。如文献[25]分析了各个 IMF 与特征分量之间的相关性,获得最优特征矩阵,再利用最小二乘支持向量机算法进行预测。文献[26]利用集成经验模态分解法将原始负荷数据分解为若干子序列,并将其按照频率高低分成低频和高频 2 部分,之后分别采用多元线性回归(multiple linear regression, MLR)和 GRU 算法进行预测,提升了预测的准确度和效率。运用 EMD 分解负荷序列虽然操作简便,但是该算法增加了预测模型的计算量,因此结合经验模态分解的混合预测算法在 EMD 分解之后,应尽量简化后续模型才能够提升整体的预测速度。

综上分析并结合现有算法,为解决电力负荷易受外界因素影响和目前结合经验模态分解的预测模型计算量大的问题,本文提出一种基于聚类经验模态分解(cluster empirical mode decomposition,

CEMD)的 CNN-LSTM 混合预测算法(CEMD-CNN-LSTM)。该方法首先通过 EMD 算法将负荷数据分解为若干本征模态分量和残差,降低负荷序列的随机性和非平稳性。其次为了降低计算复杂度,对分解所得的分量使用 k-means 进行聚类,分析不同聚类数对应的预测误差,选出最优聚类结果,根据最优聚类标签将各组分量的分量进行相加,并以滑动时间窗口方式将其构造为神经网络输入数据。之后将各组分数据分别输入到 CNN-LSTM 混合神经网络中,利用 CNN 充分提取数据之间的特征形成特征向量,并将其输入到 LSTM 中进行预测。最后将各组的预测数据进行线性相加后得到完整的负荷预测结果。与传统算法相比,本文算法在一定程度上克服了复杂环境因素对电力负荷的影响,提高了预测的准确度,与其他结合经验模态分解的预测模型相比,该算法在保证预测精度的同时减少了模型的计算量,提升了预测效率。

1 算法模型原理

1.1 聚类经验模态分解 CEMD

用户用电负荷在天气、日期类型、电价等复杂因素影响下,局部表现出较强的随机性,这使得传统方法对于超短期负荷进行准确的预测较为困难。经验模态分解法可以根据负荷序列的自身时间尺度,将数据分解为频率由高到低的多个本征模态函数(intrinsic mode functions, IMF)和残差(residual, Res),每个 IMF 代表了电力负荷在不同时间尺度上的特征分量,互不干扰。其中任意本征模态函数要满足以下 2 个条件:本征模态函数极值点的数量与零点的数量相差不大于 1;任意时刻,本征模态函数上下包络线的均值为零。运用 EMD 对负荷数据分解的步骤如下:

1) 找出原始负荷序列 $P(t)$ 中所有的极大值点和极小值点,将所有极大值点相连形成上包络线 $e_{\max}(t)$,对极小值点用同样的处理方法形成下包络线 $e_{\min}(t)$ 。

2) 计算上包络线 $e_{\max}(t)$ 和下包络线 $e_{\min}(t)$ 的平均值 $e_{\text{avi}}(t)$ 。

$$e_{\text{avi}}(t) = \frac{e_{\max}(t) + e_{\min}(t)}{2} \quad (1)$$

3) 用 $P(t)$ 减 $e_{\text{avi}}(t)$ 得到新时间序列 $T_1(t)$ 。

$$T_1(t) = P(t) - e_{\text{avi}}(t) \quad (2)$$

4) 若 $T_1(t)$ 满足 IMF 的 2 个条件,则 $T_1(t)$ 为第 1 个 IMF,否则令 $T_1(t)$ 为新的时间序列重复步骤 1) — 3),直到重复 k 次后 $T_k(t)$ 满足 IMF 条件或者到达设

置的最大迭代次数,此时将其记为第 1 个 IMF,即

$$f_{\text{IMF1}}(t) = T_k(t) \quad (3)$$

5) 将原始负荷序列减去第 1 个本征模态分量 $f_{\text{IMF1}}(t)$ 即可得到残差 $R_1(t)$ 。

$$R_1(t) = P(t) - f_{\text{IMF1}}(t) \quad (4)$$

6) 将 $R_1(t)$ 视为新的负荷数据重复步骤 1) — 5),直到残差 $R_n(t)$ 满足: $R_n(t)$ 的幅值小于预设值;序列变为单调序列。此时即得到了原始负荷序列 $P(t)$ 的全部 IMF 和残余分量。

经过步骤 1) — 6) 处理,可将负荷序列分解为频率由高到低的若干 IMF 和 Res。若对分解后的所有分量都建立 CNN-LSTM 预测模型则计算量过于庞大,因此在进行后续预测时可以先对分解后的分量进行聚类集成,之后再行负荷预测。

聚类算法作为一种重要的数学统计方法被广泛应用于数据分类问题中。本文首先对 EMD 分解后的分量运用 k-means 算法进行分类,使得同组分量的时序特征最大相似化,不同组分量的时序特征最大差异化。根据聚类标签,将同组分量进行线性相加形成若干新的时序序列,经过聚类集成处理后数据量大大减小且新时序序列的时间特征更加突出,之后将这些序列分别构造为神经网络输入数据并传入到 CNN-LSTM 混合神经网络中进行预测。将分解所得分量先进行聚类集成处理再进行预测,不仅减少了计算量,而且提高了预测准确率。

1.2 卷积神经网络 CNN

卷积神经网络是深度学习领域的经典算法之一,由于其内部采用权值共享、局部连接的结构,因此 CNN 在减少算法复杂度的情况下还可以有效提取数据中蕴含的深层次特征^[27]。卷积神经网络主要由对数据进行卷积计算并提取潜在特征的卷积层和对网络参数进行下采样和压缩的池化层组成。卷积层和池化层的交替使用,既可以最大程度地对输入数据的潜在特征进行有效提取,又可减少人为提取特征所带来的误差。因此本文使用卷积神经网络先对聚类经验模态分解处理后的数据进行特征提取,之后再传入到 LSTM 网络中进行预测。一维卷积神经网络结构图如图 1 所示。

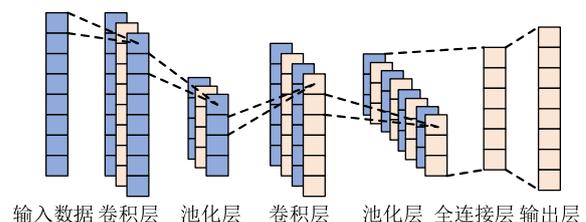


图 1 CNN 结构图

Fig. 1 Structure diagram of CNN

1.3 长短期记忆网络 LSTM

长短期记忆网络作为一种改进的时间循环神经网络，其在 RNN 的结构上增加了 3 个控制信息传递的门控单元，有效解决了 RNN 在长序列中出现的梯度消失或爆炸缺陷^[28]。LSTM 的结构如图 2 所示。长短期记忆网络依据其独特的门控结构和记忆单元可以对长时间序列进行有效处理，实现对负荷序列的历史信息进行长期保存。3 个门控单元分别是遗忘门、输入门和输出门，其中遗忘门在保留有用信息的同时避免了上一时刻的无用信息向后传递，输入门和输出门的作用是读取数据和将处理后的数据向下一个时刻传递。计算公式如式(5)—(10)所示。

$$f_t = \sigma(W_{fx}x_t + W_{fh}h_{t-1} + b_f) \quad (5)$$

$$i_t = \sigma(W_{ix}x_t + W_{ih}h_{t-1} + b_i) \quad (6)$$

$$g_t = \tanh(W_{gx}x_t + W_{gh}h_{t-1} + b_g) \quad (7)$$

$$O_t = \sigma(W_{ox}x_t + W_{oh}h_{t-1} + b_o) \quad (8)$$

$$C_t = g_t i_t + C_{t-1} f_t \quad (9)$$

$$h_t = \tanh(C_t) O_t \quad (10)$$

式中： W 为权值； b 为偏置； σ 为 sigmoid 函数。每个时刻的输入变量包含上一时刻的单元状态 C_{t-1} ；上一时刻的中间状态 h_{t-1} ；以及当前时刻的输入 x_t ；中间变量包括遗忘门的输出 f_t ；输入输出门的输出 i_t 和 O_t ，以及输入节点的输出 g_t ；输出变量包括单元状态 C_t 和中间状态 h_t 。

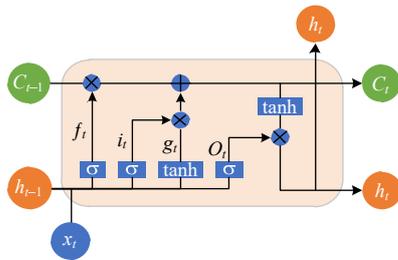


图 2 LSTM 结构图

Fig. 2 Structure diagram of LSTM

2 CEMD-CNN-LSTM 模型

本文将数据预处理算法和神经网络模型相结合，提出了基于聚类经验模态分解的 CNN-LSTM 预测模型。利用聚类经验模态分解算法对负荷数据进行预处理，之后利用 CNN-LSTM 混合神经网络进行预测。该算法不仅可以减小外界因素对超短期负荷预测的影响提高预测精度，还可以降低模型运算体量提高预测效率。

由于超短期负荷数据易受到多种因素影响，因此首先采用 EMD 算法，将归一化后原始负荷数据分解为若干个 IMF 和 Res。如果对每一个分量单独进

行预测会导致模型计算量过大，因此为了减少后续模型的计算量，采用 k-means 算法将分解所得的 IMF 和 Res 进行聚类。根据聚类结果将同组内的分量进行叠加形成新的时间序列，之后再将其分别传入到神经网络中进行预测。本文所提算法结构如图 3 所示。

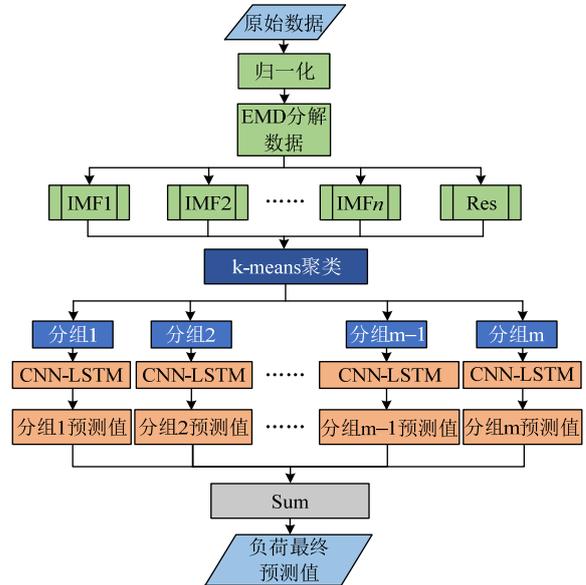


图 3 基于 CEMD 的 LSTM-CNN 模型结构图

Fig. 3 Structure diagram of LSTM-CNN model based on CEMD

将聚类经验模态分解处理后的各分量分别传 入到 CNN-LSTM 混合神经网络中，混合神经网络结构包括输入层、CNN 网络层、LSTM 网络层和输出层。其中输入层的作用是将聚类处理后的分量作为输入数据传入到 CNN 中，利用 CNN 的结构特点对输入数据进行充分的挖掘，获取输入序列的主要特征。CNN 网络层由 2 层一维卷积层和一层最大池化层组成，卷积层的作用为获取输入数据的特征，2 层均选择 ReLU 作为激活函数。在卷积层之后进行最大池化操作，对卷积层所提取的特征进行下采样，以精简模型参数。随后将 CNN 网络提取到的特征传入到 LSTM 网络中，通过 LSTM 对提取到的特征进行充分学习，以获取数据间的内在联系和周期性规律，并对未来的数据进行预测。LSTM 网络由 2 层 LSTM 层(一层全连接层，一层 Dropout 层)组成。LSTM 层的作用是对 CNN 层提取的特征进行学习，保留有用信息，遗忘无效信息。由于经过聚类经验模态分解处理后的大部分分量都具有较强的规律性，因此 LSTM 的层数选择为 2 层，这样可以保证在较短训练的时间内达到更好的预测效果。在 2 层 LSTM 之后加一个全连接层是为了在输出层之前压缩数据，减少数据流的体量和输出层的网络参数，加入 Dropout 层的目的是在一定程度上减小

过拟合现象。输出层为一层全连接层，目的是将 LSTM 层的输出通过全连接后计算出预测值并输出。最后将各组的预测结果叠加得到完整的负荷预测值，混合神经网络结构如图 4 所示。

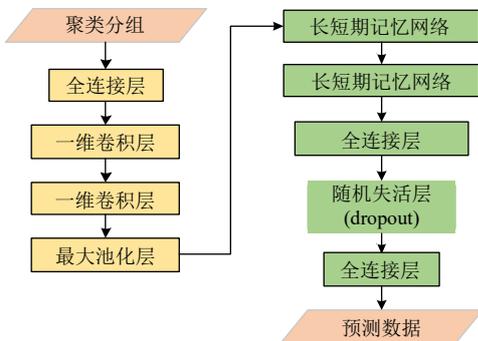


图 4 CNN-LSTM 结构图
Fig. 4 Structure diagram of CNN-LSTM

3 实例分析

本算例的数据来源为比利时蒙斯大学采集的当地某个用户的用电数据^[29]，采集时间为 2016 年 1 月 11 日 17:00 至 2016 年 5 月 27 日 18:00，采样间隔为 10min，数据集共计 19735 条数据。采用常用评估指标，将本文所提算法(CEMD-CNN-LSTM，简称 CECL)所得预测结果与反向传播神经网络(back propagation neural network, BPNN)、支持向量机(support vector machine, SVM)、CNN-GRU^[17]、CNN-LSTM^[18]、EMD-CNN-LSTM(简称 ECL)算法的预测结果进行对比，证明本文算法的优越性。

3.1 数据归一化及评估指标

为了评估本文所提算法和对比算法的预测准确度，本算例采用平均绝对百分误差(mean absolute percentage error, MAPE)、平均绝对误差(mean absolute error, MAE)和均方根误差(root mean square error, RMSE)为评价指标。各评估指标的计算公式为

$$L_{MAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{y_i} \times 100\% \quad (11)$$

$$L_{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (12)$$

$$L_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (13)$$

式中： n 为预测点个数； \hat{y}_i 和 y_i 分别为测试集中第 i 个负荷点的预测数据和真实数据。

为了使模型更好地学习数据之间的规律，因此采用最大最小归一化^[30]将数据压缩到 $[0, 1]$ 之间。归一化公式为

$$l' = \frac{l - l_{\min}}{l_{\max} - l_{\min}} \quad (14)$$

式中： l' 为归一化后的数据； l 为要归一化的数据；

l_{\min} 和 l_{\max} 分别为负荷数据的最小值和最大值。

3.2 EMD 分解及 k-means 聚类

将归一化的负荷数据经过经验模态分解法分解后共得到 17 个分量，其中包括 16 个 IMF 和 1 个 Res，将其记为 $e_1 - e_{17}$ ，分解后的序列如图 5 所示。由图可知分解后的各个 IMF 的频率比较稳定，表现出较为明显的周期性，且没有出现模态混叠现象。

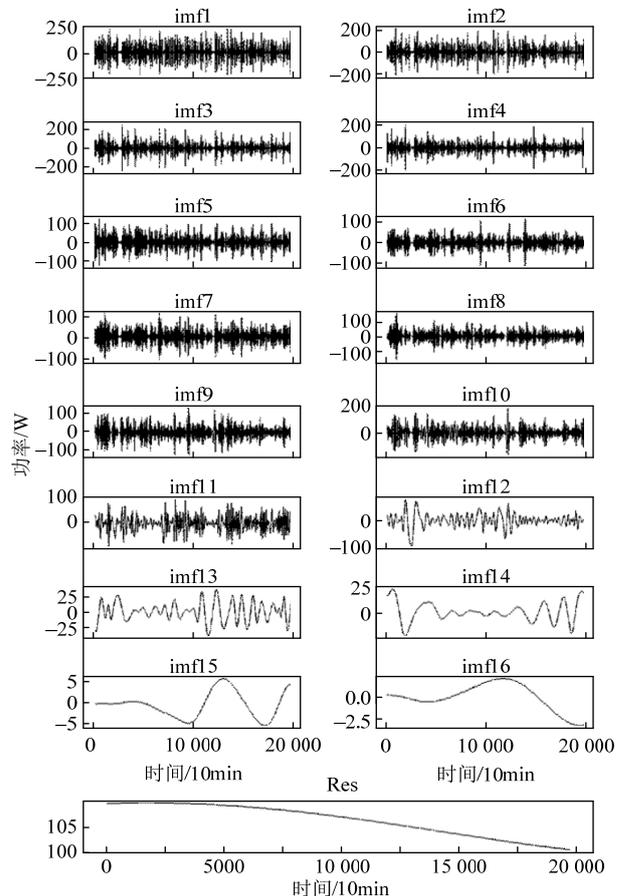


图 5 负荷数据分解后的 IMF 分量
Fig. 5 IMF component after load data decomposition

为了减少后续模型的计算量，使用 k-means 算法通过选取不同聚类数 d ，对子序列 $e_1 - e_{17}$ 进行聚类。根据聚类标签将分解后的 17 个子序列分类为 d 个分组，并将每个组内的子序列进行叠加后得到新的序列，记为 $k_1 - k_d$ 。之后将 $k_1 - k_d$ 按照滑动窗口的方式构建成神经网络输入数据，分别输入到 CNN-LSTM 神经网络中进行预测。不同聚类数对应的预测误差如图 6 所示，相应的训练和预测所需时间以及详细的预测误差数值如表 1 所示。

通过表 1 可知，当设置聚类数为 10 时预测误差最低，当聚类数为 17 时，即不进行聚类直接对各个分量进行预测，不仅预测精度会降低而且时间非常缓慢，当聚类数设置为 1 时，即将所有分解后的分量加在一起再进行预测，虽然时间很短但是精度较低且失去了经验模态分解的意义。因此设置合理

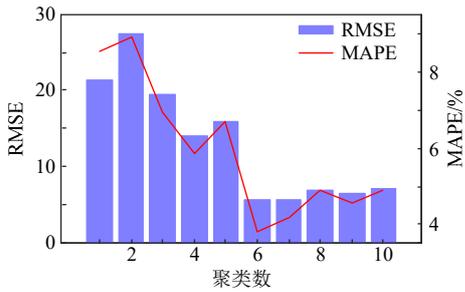


图 6 不同聚类数的预测误差

Fig. 6 Prediction error of different cluster numbers

表 1 不同聚类数对应的预测误差和所需时间

Table 1 Prediction error and time required for different cluster numbers

聚类数	MAE	MAPE/%	RMSE	时间/s
1	14.160	8.531	21.339	160.838
2	19.527	8.919	27.372	328.216
4	12.633	6.934	19.435	666.348
6	8.169	5.861	14.074	1002.822
8	10.076	6.693	15.918	1316.936
10	4.357	3.821	5.514	1630.899
12	5.113	4.195	5.691	1960.968
14	6.026	4.895	6.935	2439.710
16	5.311	4.549	6.523	2650.832
17	5.027	4.911	7.019	2730.219

的聚类数不仅提高预测效率，还可以提高预测精度。

3.3 预测与结果分析

本文采用窗口滑动处理规则将聚类集成处理后的时间序列数据，以 24h 为时间步长重构成神经网络输入数据，将前 143 个数据(即前 23h50min 的数据)作为特征，第 144 个数据(即最后 10min 的数据)作为标签。根据聚类标签，将分解所得的序列进行集成得到 10 个新时间序列，并将其均升维至大小为[19455, 144, 1]的子数据集，之后将每个子数据集作为神经网络的输入数据分别传入到 CNN-LSTM 混合神经网络中进行预测，其中各子数据集均采用 2016 年 5 月 26 号 18:00 之前的数据作为训练数据，预测 2016 年 5 月 26 日 18:00 至 2016 年 5 月 27 日 18:00 共计 24h，144 个点的数据。得到每个分组的预测结果后将各个预测值相加获得完整的预测负荷。预测结果如图 7 所示，蓝色为真实

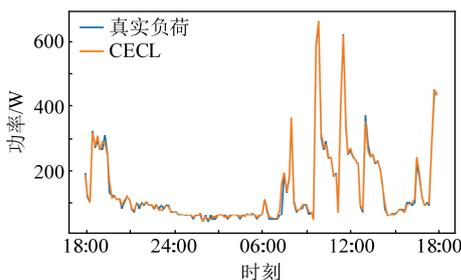


图 7 本文所提模型最终预测结果

Fig. 7 Final prediction results of the model proposed in this paper

负荷数据，橘色为预测数据，可以看出预测数据和真实负荷基本吻合。

将本文所提算法预测结果与传统单一模型或混合深度学习模型的预测结果进行对比，对比结果如图 8、9 所示。图 8 为本文算法与传统单一模型对比结果图，其中橘色曲线为真实负荷，粉色曲线为 BPNN 预测负荷，灰色曲线为 SVM 预测负荷，蓝色虚线为本文所提算法的预测负荷。图 9 为本文算法与其他混合深度学习模型对比结果图，其中橘色曲线为真实负荷，黑色曲线为 CNN-GRU 预测负荷，绿色曲线为 CNN-LSTM 预测负荷，棕色曲线为 ECL 的预测负荷，蓝色虚线为本文所提算法的预测负荷。两图中的子图均为各主图局部曲线的缩放图，可看出相对于其他算法，本文所提模型与真实数据具有更高的吻合度。

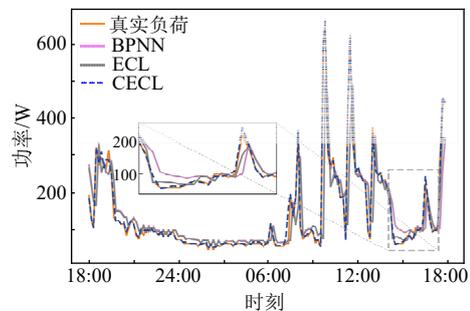


图 8 所提模型预测值与传统单一模型的对比图

Fig. 8 Comparison of the predicted values of the proposed model with traditional signal models

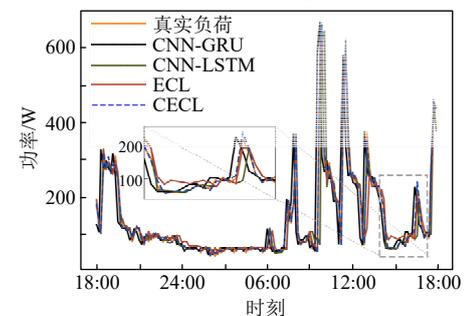


图 9 所提模型预测值与混合深度学习模型的对比图

Fig. 9 Comparison of the predicted values of the proposed model with hybrid deep learning models

表 2 给出了本文所提模型以及其他模型预测结果的评估指标，从平均绝对百分误差的角度来看，本文所提算法(CECL)与 BPNN、SVM、CNN-LSTM、CNN-GRU 以及 ECL 模型相比，MAPE 分别下降了 14.974%、6.191%、3.93%、2.254%、1.09%；从平均绝对误差角度看，相对于其他算法 MAE 分别下降了 27.227、14.802、9.521、6.064、0.67；从均方根误差角度看，相对于其他算法 RMSE 分别下降了 68.332、27.826、18.778、11.564、1.505。综上所述，本文所提出的基于聚类经验模态分解的 CNN-

表 2 各模型预测误差对比

Table 2 Comparison of prediction errors of each model

模型	MAE	MAPE/%	RMSE
BPNN	31.584	18.795	73.846
SVM	19.159	10.012	33.340
CNN-GRU ^[17]	13.878	7.751	24.292
CNN-LSTM ^[18]	10.421	6.075	17.078
ECL	5.027	4.911	7.019
CECL	4.357	3.821	5.514

LSTM 混合预测算法相对于其他算法具有更高的预测精度。

4 结论

本文提出了一种基于聚类经验模态分解的 CNN-LSTM 超短期负荷预测模型。相比于现有方法，本文算法有如下优势：

1) 该方法将混有高频噪音，随机性强的原始负荷数据经过经验模态分解后得到若干频率由高到低的本征模态分量和残差，降低了原始负荷数据的非平稳性，改善了负荷数据质量。

2) 运用 k-means 算法将分解后时序特征相似的分量进行聚类集成处理并得到新的时间序列，新序列的时序特征更加突出，有利于神经网络学习预测提高预测精度，同时也减少了后续模型的计算复杂度，提高模型整体训练预测速度。

3) 将新的时间序列分别传入到 CNN-LSTM 混合神经网络中，利用 CNN 充分挖掘数据间的特征，并利用 LSTM 进行预测，克服了单一 LSTM 模型对非连续数据间的隐含信息不能有效挖掘的缺陷，有效提高了预测精度。

本文提出的基于聚类经验模态分解的 CNN-LSTM 混合预测模型，具有一定的实际意义：与传统单一算法及其他混合神经网络算法相比本文算法提高了预测的准确度；与其他结合经验模态分解的预测模型相比，该算法在保证预测精度的同时提高了训练和预测的速度。

参考文献

[1] 中国电力企业联合会. 《2018~2019 年度全国电力供需形势分析预测报告》速览[J]. 中国电力企业管理, 2019(3): 7.
CHINA ELECTRICITY COUNCIL. A quick overview of the national electric power supply and demand situation analysis and forecast report for 2018-2019[J]. China Power Enterprise Management, 2019 (3): 7(in Chinese).

[2] 范士雄, 李立新, 王松岩, 等. 人工智能技术在电网调控中的应用研究[J]. 电网技术, 2020, 44(2): 401-411.
FAN Shixiong, LI Lixin, WANG Songyan, et al. Application analysis and exploration of artificial intelligence technology in power grid dispatch and control[J]. Power System Technology, 2020, 44(2): 401-411(in Chinese).

[3] 张涛, 顾洁. 高比例可再生能源电力系统的马尔科夫短期负荷预测方法张涛, 顾洁[J]. 电网技术, 2018, 42(4): 1071-1078.
ZHANG Tao, GU Jie. Markov short-term load forecasting method for power system with high proportion renewable energy[J]. Power System Technology, 2018, 42(4): 1071-1078(in Chinese).

[4] 杨德昌, 赵肖余, 何绍文, 等. 面向海量用户用电数据的集成负荷预测[J]. 电网技术, 2018, 42(9): 2923-2929.
YANG Dechang, ZHAO Xiaoyu, HE Shaowen, et al. Aggregated load forecasting based on massive household smart meter data[J]. Power System Technology, 2018, 42(9): 2923-2929(in Chinese).

[5] LIU Yu, LI Zhi, BAI Kai, et al. Short-term power-forecasting method of distributed PV power system for consideration of its effects on load forecasting[J]. Journal of Engineering, 2017, 2017(13): 865-869.

[6] SABER A Y, ALAM A K M R. Short term load forecasting using multiple linear regression for big data[C]//2017 IEEE Symposium Series on Computational Intelligence (SSCI). Honolulu: IEEE, 2017: 1-6.

[7] 陈培垠, 方彦军. 基于卡尔曼滤波预测节假日逐点增长率的电力系统短期负荷预测[J]. 武汉大学学报, 2020, 53(2): 139-144.
CHEN Peiyin, FANG Yanjun. Short-term load forecasting of power system for holiday point-by-point growth rate based on Kalman filtering[J]. Engineering Journal of Wuhan University, 2020, 53(2): 139-144(in Chinese).

[8] RENDON-SANCHEZ J F, DE MENEZES L M. Structural combination of seasonal exponential smoothing forecasts applied to load forecasting[J]. European Journal of Operational Research, 2019, 275(3): 916-924.

[9] 肖白, 黄钰茹, 姜卓, 等. 数据匮乏场景下采用生成对抗网络的空间负荷预测方法[J]. 中国电机工程学报, 2020, 40(24): 7990-8001.
XIAO Bai, HUANG Yuru, JIANG Zhuo, et al. The method of spatial load forecasting based on the generative adversarial network for data scarcity scenarios[J]. Proceedings of the CSEE, 2020, 40(24): 7990-8001(in Chinese).

[10] ZHU Xianghe, SHEN Min. Based on the ARIMA model with grey theory for short term load forecasting model[C]//2012 International Conference on Systems and Informatics. Yantai: IEEE, 2012: 564-567.

[11] DAI Yeming, ZHAO Pei. A hybrid load forecasting model based on support vector machine with intelligent methods for feature selection and parameter optimization[J]. Applied Energy, 2020, 279: 115332.

[12] YANG Ailing, LI Weide, YANG Xuan. Short-term electricity load forecasting based on feature selection and Least Squares Support Vector Machines[J]. Knowledge-Based Systems, 2019, 163: 159-173.

[13] MASSAOUDI M, REFAAT S S, CHIHI I, et al. A novel stacked generalization ensemble-based hybrid LGBM-XGB-MLP model for Short-Term Load Forecasting[J]. Energy, 2021, 214: 118874.

[14] 史佳琪, 张建华. 基于多模型融合 Stacking 集成学习方式的负荷预测方法[J]. 中国电机工程学报, 2019, 39(14): 4032-4041.
SHI Jiaqi, ZHANG Jianhua. Load forecasting based on multi-model by stacking ensemble learning[J]. Proceedings of the CSEE, 2019, 39(14): 4032-4041(in Chinese).

[15] 张宇帆, 艾芊, 林琳, 等. 基于深度长短期记忆网络的区域级超短期负荷预测方法[J]. 电网技术, 2019, 43(6): 1884-1892.
ZHANG Yufan, AI Qian, LIN Lin, et al. A very short-term load forecasting method based on deep LSTM RNN at zone level[J]. Power System Technology, 2019, 43(6): 1884-1892(in Chinese).

[16] 陈振宇, 刘金波, 李晨, 等. 基于 LSTM 与 XGBoost 组合模型的超短期电力负荷预测[J]. 电网技术, 2020, 44(2): 614-620.
CHEN Zhenyu, LIU Jinbo, LI Chen, et al. Ultra short-term power

- load forecasting based on combined LSTM-XGBoost model[J]. Power System Technology, 2020, 44(2): 614-620(in Chinese).
- [17] 姚程文, 杨莘, 刘泽健. 基于 CNN-GRU 混合神经网络的负荷预测方法[J]. 电网技术, 2020, 44(9): 3416-3424.
YAO Chengwen, YANG Ping, LIU Zejian. Load forecasting method based on CNN-GRU hybrid neural network[J]. Power System Technology, 2020, 44(9): 3416-3424(in Chinese).
- [18] 陆继翔, 张琪培, 杨志宏, 等. 基于 CNN-LSTM 混合神经网络模型的短期负荷预测方法[J]. 电力系统自动化, 2019, 43(8): 131-137.
LU Jixiang, ZHANG Qipei, YANG Zhihong, et al. Short-term load forecasting method based on CNN-LSTM hybrid neural network model[J]. Automation of Electric Power Systems, 2019, 43(8): 131-137(in Chinese).
- [19] HAFEEZ G, ALIMGEER K S, KHAN L. Electric load forecasting based on deep learning and optimized by heuristic algorithm in smart grid[J]. Applied Energy, 2020, 269: 114915.
- [20] 沈兆轩, 袁三男. 利用卷积神经网络支持向量回归机的地区负荷聚类集成预测[J]. 电网技术, 2020, 44(6): 2237-2244.
SHEN Zhaoxuan, YUAN Sannan. Regional load clustering integration forecasting based on convolutional neural network support vector regression machine[J]. Power System Technology, 2020, 44(6): 2237-2244(in Chinese).
- [21] 彭文, 王金睿, 尹山青. 电力市场中基于 Attention-LSTM 的短期负荷预测模型[J]. 电网技术, 2019, 43(5): 1745-1751.
PENG Wen, WANG Jinrui, YIN Shanqing. Short-term load forecasting model based on Attention-LSTM in electricity market[J]. Power System Technology, 2019, 43(5): 1745-1751(in Chinese).
- [22] HEYDARI A, NEZHAD M M, PIRSHAYAN E, et al. Short-term electricity price and load forecasting in isolated power grids based on composite neural network and gravitational search optimization algorithm[J]. Applied Energy, 2020, 277: 115503.
- [23] BENTO P M R, POMBO J A N, CALADO M R A, et al. Optimization of neural network with wavelet transform and improved data selection using bat algorithm for short-term load forecasting[J]. Neurocomputing, 2019, 358: 53-71.
- [24] FAN Chaodong, DING Changkun, ZHENG Jinhua, et al. Empirical Mode Decomposition based Multi-objective Deep Belief Network for short-term power load forecasting[J]. Neurocomputing, 2020, 388: 110-123.
- [25] 孔祥玉, 李闯, 郑锋, 等. 基于经验模态分解与特征相关分析的短期负荷预测方法[J]. 电力系统自动化, 2019, 43(5): 46-52.
KONG Xiangyu, LI Chuang, ZHENG Feng, et al. Short-term load forecasting method based on empirical mode decomposition and feature correlation analysis[J]. Automation of Electric Power Systems, 2019, 43(5): 46-52(in Chinese).
- [26] 邓带雨, 李坚, 张真源, 等. 基于 EEMD-GRU-MLR 的短期电力负荷预测[J]. 电网技术, 2020, 44(2): 593-602.
DENG Daiyu, LI Jian, ZHANG Zhenyuan, et al. Short-term electric load forecasting based on EEMD-GRU-MLR[J]. Power System Technology, 2020, 44(2): 593-602(in Chinese).
- [27] 赵兵, 王增平, 纪维佳, 等. 基于注意力机制的 CNN-GRU 短期电力负荷预测方法[J]. 电网技术, 2019, 43(12): 4370-4376.
ZHAO Bing, WANG Zengping, JI Weijia, et al. A short-term power load forecasting method based on attention mechanism of CNN-GRU[J]. Power System Technology, 2019, 43(12): 4370-4376(in Chinese).
- [28] 李鹏, 何帅, 韩鹏飞, 等. 基于长短期记忆的实时电价条件下智能电网短期负荷预测[J]. 电网技术, 2018, 42(12): 4045-4052.
LI Peng, HE Shuai, HAN Pengfei, et al. Short-term load forecasting of smart grid based on long-short-term memory recurrent neural networks in condition of real-time electricity price[J]. Power System Technology, 2018, 42(12): 4045-4052(in Chinese).
- [29] CANDANEDO L. Appliances energy prediction Data Set [DB/OL]. [2017-02-15/2021-01-03]. <http://archive.ics.uci.edu/ml/datasets/Appliances+energy+prediction>.
- [30] 赵佩, 代业明. 基于实时电价和加权灰色关联投影的 SVM 电力负荷预测[J]. 电网技术, 2020, 44(4): 1325-1332.
ZHAO Pei, DAI Yeming. Power load forecasting of SVM based on real-time price and weighted grey relational projection algorithm[J]. Power System Technology, 2020, 44(4): 1325-1332(in Chinese).



刘亚琿

在线出版日期: 2021-04-21。

收稿日期: 2021-01-05。

作者简介:

刘亚琿(1997), 男, 硕士研究生, 研究方向为深度学习, 电力负荷预测等, E-mail: yahuiliusuep@163.com;

赵倩(1969), 女, 副教授, 硕士生导师, 通信作者, 研究方向为视频图像处理、深度学习、智能电网、数字系统设计等, E-mail: zhaoqian@shiep.edu.cn。

(实习编辑 宋钰龙)