

基于 VMD 和 TCN 的多尺度短期电力负荷预测



刘杰*, 金勇杰, 田明

(哈尔滨理工大学测控技术与通信工程学院 哈尔滨 150080)

【摘要】 准确的电力负荷预测对于保证电力系统的稳定运行起着重要作用。针对传统短期电力负荷预测方法预测精度低, 模态分解后未考虑子序列融合等问题, 提出一种基于变分模态分解 (VMD) 和时域卷积网络 (TCN) 的多尺度短期电力负荷预测方法。首先利用 VMD 将电力负荷数据分解为若干个子序列, 解决电力负荷数据的非线性和随机性等问题; 再利用 TCN 对若干个序列采用不同时间尺度进行训练; 最后利用全连接网络 (FC) 对各时间尺度的子序列进行融合, 实现短期电力负荷预测, 提升预测精度。实验结果表明, 该方法相较于 VMD 和改进的长短时记忆网络 (LSTM) 相结合的传统预测方法, 其均方根误差下降 40%, 曲线拟合程度提升 1.1%。

关键词 短期电力负荷预测; 子序列融合; 时域卷积网络; 变分模态分解

中图分类号 TH17 **文献标志码** A **doi:**10.12178/1001-0548.2021347

Multi-Scale Short-Term Load Forecasting Based on VMD and TCN

LIU Jie*, JIN Yongjie, and TIAN Ming

(School of Measurement and Control Technology and Communication Engineering, Harbin University of Science and Technology Harbin 150080)

Abstract Accurate power load forecasting plays an important role in ensuring the stable operation of the power system. In view of the low precision of traditional short-term power load forecasting methods, the sub-sequence fusion problem is not considered after modal decomposition, this paper proposes a multi-scale short-term power load forecasting based on variational mode decomposition (VMD) and temporal convolutional network (TCN) methods. First, VMD is used to decompose the power load data into several sub-components to solve the problems of non-linearity and randomness in the power load data, then TCN is applied to train several components with different time scales, finally a fully connected network is used to analyze each component. Time-scale decomposition signals are fused to realize short-term power load forecasting and improve forecasting accuracy. The experimental results show that the root mean square error (RMSE) is reduced by 40% and the curve fitting is improved by 1.1% compared with the traditional prediction method of VMD and improved long-short-term memory network.

Key words short-term power load forecasting; subsequence fusion; temporal convolution network; variational mode decomposition

短期电力负荷预测是指以分、小时、天、周为单位的负荷预测^[1-3]。现阶段的短期电力负荷预测模型主要分为时间序列模型和特征学习模型两大类。时间序列模型中自回归差分滑动平均模型 (autoregressive integrated moving average, ARIMA) 已经用于很多负荷预测中, 包括中长期电力负荷预测^[4]; 特征学习模型主要为神经网络模型, 包括 BP 神经网络^[5]、长短时记忆网络 (long short-term

memory, LSTM)^[6-7] 和支持向量机 (support vector network, SVM) 等^[8]。BP 神经网络存在网络结构简单、预测精度低等问题; 支持向量机在小数据集上表现良好但仍存在预测准确性较低等问题, 且上述两种网络均未考虑到数据之间相关性, 难以表征时域特征。现实生活中过早的电力负荷数据会造成预测训练数据过少, 难以用于目前的电力负荷预测, 使得 LSTM 等模型训练难度较大且训练精度较低^[9]。

收稿日期: 2021-11-19; 修回日期: 2022-02-25

基金项目: 国家自然科学基金 (51607049)

作者简介: 刘杰 (1980-), 博士, 主要从事图像传输与处理、机器学习与模式识别等方面的研究。

*通信作者: 刘杰, E-mail: liujie@hrbust.edu.cn

文献 [10] 提出了时域卷积网络 (temporal convolutional network, TCN), 在小数据集上训练效果和训练时间相较于传统方法有着更为理想的表现。

现阶段很多学者考虑到了负荷数据存在随机性、周期性、非线性等特点。利用经验模态分解 (empirical mode decomposition, EMD) 将负荷数据分解成多组分解数据再进行预测, 可提升预测的准确度^[11]。但是该算法易出现模态混叠等问题, 造成后续预测精度的降低。变分模态分解 (variational mode decomposition, VMD) 的提出, 不仅可以解决模态混叠, 还可以有效解决负荷数据存在随机性和非线性等问题。通过将 VMD 与 LSTM 相结合的方法对短期电力负荷进行预测, 降低了数据的复杂度, 解决了数据存在随机性、非线性等特点, 但是小样本上训练精度仍可以提升^[12]。文献 [13] 在 TCN 的基础上对时间和空间尺度上提出了多尺度时域卷积网络 (multi-temporal-spatial-scale temporal convolutional network, MTCN), 该方法使得网络可以更好地表征时域上的特征并提升预测精度, 但当数据复杂度过高时, 预测精度不够, 且网络中仍存在可优化的部分。因此本文构建了一种 VMD-MTCN-COSA-FC 的电力负荷预测方法, 利用 VMD 将电力负荷数据进行分解, 将分解的分量送入 TCN 网络中利用不同的时间尺度进行训练, 同时在 TCN 网络训练时利用余弦退火衰减优化算法 (cosine annealing, COSA) 优化神经网络训练中的学习率参数, 最后利用全连接网络 (fully connected networks, FCN) 对每个分解信号的预测结果进行训练融合, 获得最终的预测结果。

1 VMD-MTCN-COSA-FC 的短期电力负荷预测系统构建

多尺度的变分模态预测方法是指通过变分模态分解将原始数据分解为多个模态, 并对分解的多个模态利用不同尺度进行训练预测。VMD-MTCN-COSA-FC 网络系统框图如图 1 所示。原始负荷数据经过 VMD 分解后, 获得 K 个模态分量; 将 K 个模态分量分别送入 TCN 网络, 并采用 K 种尺度进行训练, 降低负荷数据复杂度, 解决数据中存在随机性和非线性等问题; 对训练网络的学习率采用余弦退火进行优化, 输出 K 个模态分量对应的 K 个预测结果, 防止网络陷入局部最优解, 这样不仅能缩短训练时间还可以提升预测精度; K 个预测结果作为全连接网络的输入, 通过全连接网络对模

态进行融合, 获得最终预测结果输出, 使得预测结果能够考虑模态之间的相关性及各模态自身的重要性, 进一步提升预测准确率, 最终实现对原始数据的预测。

1.1 VMD 算法

VMD 算法常用于处理非平稳信号^[14-15], 可有效地提取出电力负荷数据的特征。

对于输入信号, VMD 算法由此产生约束的变分问题为:

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\delta(t) + \frac{j}{\pi t} \right] * u_k(t) e^{-j\omega_k t} \right\|_2^2 \right\} \quad (1)$$

$$\text{s.t.} \sum_k u_k = f \quad (2)$$

式中, $u_k = \{u_1, u_2, \dots, u_k\}$ 为分解出来的 K 个模态分量; $w_k = \{w_1, w_2, \dots, w_k\}$ 为各模态的中心频率; “*” 表示卷积运算; ∂_t 表示对函数求时间的导数; $\delta(t)$ 表示单位脉冲函数。

引入二次惩罚项 a 和拉格朗日算子 λ , 将有约束算法转变为无约束的变分问题:

$$L(\{u_k\}, \{\omega_k\}, \lambda) := a \sum_k \left\| \partial_t \left[\delta(t) + \frac{j}{\pi t} \right] * u_k(t) e^{-j\omega_k t} \right\|_k^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle \quad (3)$$

利用交替方向乘子算法, 不断迭代更新 w_k^{n+1} , u_k^{n+1} 和 λ , 求得该变分问题的最优解, 其中迭代过程为:

$$\hat{u}_k^{n+1}(w) = \frac{\hat{f}(w) - \sum_{i \neq k} \hat{u}_i(w) + \frac{\hat{\lambda}(w)}{2}}{1 + 2a(w - w_k)^2} \quad (4)$$

$$w_k^{n+1} = \frac{\int_0^\infty w |\hat{u}_k(w)|^2 dw}{\int_0^\infty |\hat{u}_k(w)|^2 dw} \quad (5)$$

$$\hat{\lambda}^{n+1}(w) = \hat{\lambda}^n(w) + \tau(\hat{f}(w) - \sum_k \hat{u}_k^{n+1}(w)) \quad (6)$$

式中, τ 为信号的噪声容忍度。通过反复迭代直到满足收敛条件或达到最大迭代次数即停止, 收敛条件为:

$$\sum_k \|\hat{u}_k^{n+1} - \hat{u}_k^n\| / \|\hat{u}_k^n\| < \varepsilon \quad (7)$$

本文采用电力负荷数据包含每一天的使用数据、整体电力负荷使用趋势以及数据的随机波动, 通过 VMD 对数据进行分解, 降低数据复杂度, 解决原始数据存在的随机性和非线性等问题, 提升后续每一次训练预测的准确度。

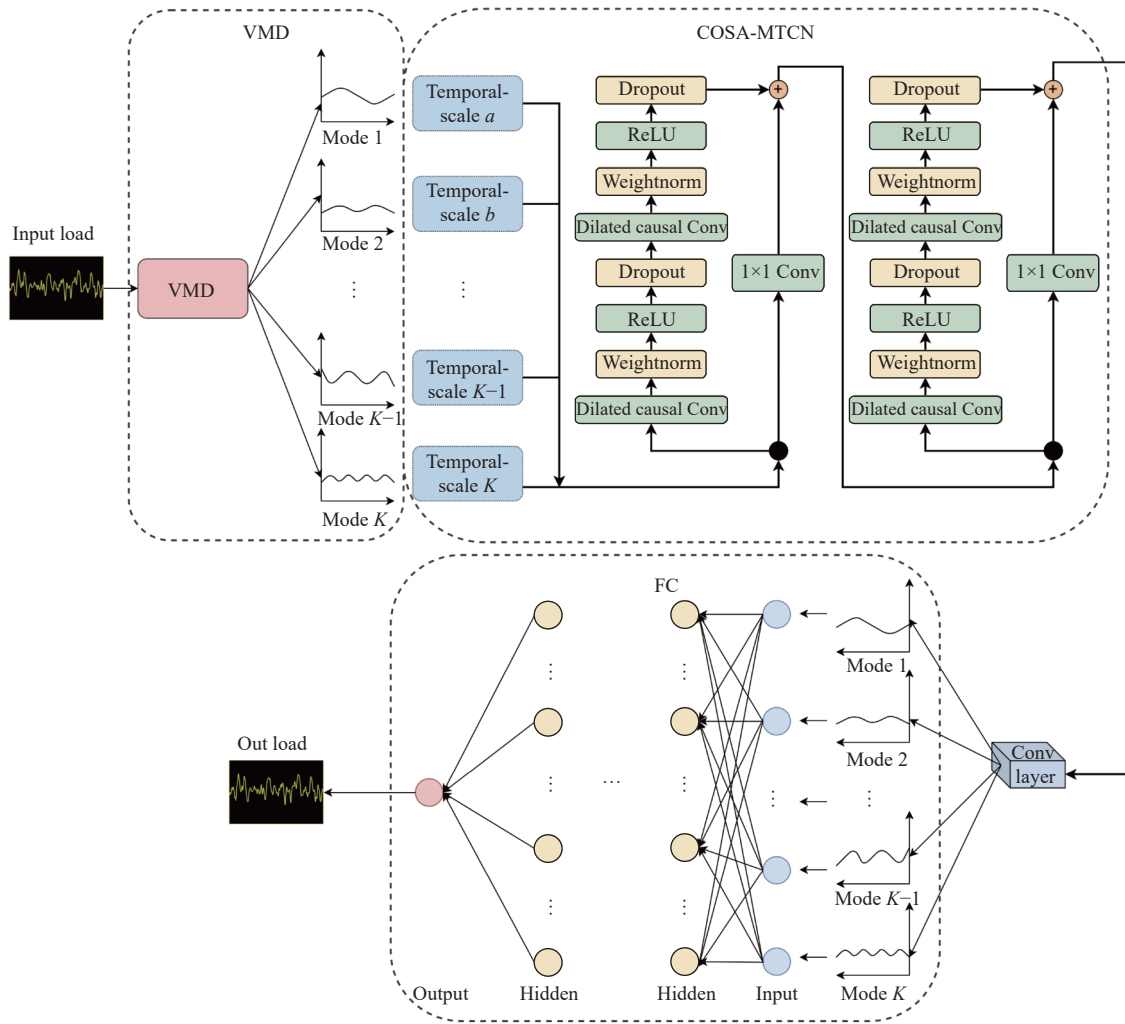


图 1 VMD-COSA-MTCN-FC 网络系统框图

1.2 TCN 网络

TCN 是一种用于解决时间序列问题的网络，能够有效提取出数据之间的关联性^[16-17]，并对后续数据进行预测，TCN 主要结构为膨胀因果卷积。

膨胀卷积通过跳过部分输入的方式，将卷积核作用于更大的区域。膨胀卷积通过改变膨胀系数来调整感受野的大小，使网络能够灵活的调整输出所接收到的历史信息量。对于一维序列的输入 $x \in R^n$ 和滤波器 $f: \{0, 1, \dots, k-1\} \rightarrow R$ ，卷积核可以通过滤波器系数 k 和膨胀系数 d 将感受野扩张，膨胀卷积运算为：

$$F(x) = \sum_{i=0}^{k-1} f(i) \cdot x_{s-d \cdot i} \quad (8)$$

式中， d 为膨胀系数； $s-d \cdot i$ 为输入序列中的历史数据； k 为滤波器系数。

膨胀因果卷积如图 2 所示，从图中可以看出输出序列中 Y_T 点的感受野大小通过 k 和 d 来调整，且

该点输出只受之前的历史数据影响。本文使用的 TCN 网络采用膨胀系数 $d=1, 2, 4, 8$ ，滤波器系数 $k=3$ 的膨胀因果卷积。通过灵活的调整感受野，充分的考虑电力负荷数据中的时域特征，根据输入时间尺度的不同，调整输出结点记忆的长短，能够较好地解决传统方法中存在的对历史数据遗忘的问题，更适用于短期电力负荷预测。




图 2 膨胀因果卷积

1.3 余弦退火衰减

余弦函数值随着 X 的增大,先缓慢降低再加速下降最后再缓慢下降,因此可以通过余弦函数实现在网络初步训练时先用较大学习率加快模型收敛并跳出局部最优解;再用较小学习率帮助模型贴近全局最优解。余弦退火的原理如下:

$$y_t = y_{\min} + \frac{1}{2}(y_{\max} - y_{\min})(1 + \cos(\frac{T_{\text{cur}}}{T_i}\pi)) \quad (9)$$

式中, y_{\min} 和 y_{\max} 分别表示学习率最小值和最大值; T_{cur} 表示当前迭代次数; T_i 表示总迭代次数。

本文采用 VMD 对原始数据进行分解,分解获得多个子序列,且后续针对每个子序列采用不同的时间尺度进行训练,增加网络训练时间。通过引入余弦退火算法对网络内部的学习率参数进行优化,加快模型收敛减少训练时间。其中本文采用的余弦退火衰减如图 3 所示,通过余弦退火先将学习率上升至 0.01,再经过 2 000 次迭代更新后,从大学习率 0.01 降到小学习率 0.000 1。




图3 余弦退火衰减

2 实验过程及参数确定

2.1 数据集及评价指标

本文采用电工数学建模竞赛负荷预测数据集,数据为某地区 3 年内的日需求负荷数据,以天为采样频率,共 1 106 天,包括最高、最低、平均温度、相对湿度、降雨量以及日需求负荷这 6 维数据。由于湿度、气温和降雨等随机因素会提升负荷预测的复杂度,且增加了数据维度,因此本文实验仅采用电力负荷数据进行预测,选取其中 1 000 组数据,以 8:2 划分训练数据和测试数据,并选取训练集中的 5% 作为验证。评价指标选用均方根误差 (RMSE)、平均绝对误差 (MAE) 和 R^2 对实验结果进行评估。其公式分别为:

$$\text{RMSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (10)$$

$$\text{MAE} = \left| \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i) \right| \quad (11)$$


$$R^2 = 1 - \frac{\sum_{i=1}^m (y_i - \hat{y}_i)^2}{\sum_{i=1}^m (y_i - \bar{y})^2} \quad (12)$$

式中, m 为样本数量; y_i 为真实值; \hat{y}_i 为预测值; \bar{y} 为真实值的平均值。

本文实验环境为 Intel Core i5-7400 CPU, NVIDIA GeForce GTX 1050 的 4 GB 和 8 GB RAM。采用深度学习框架为 tensorflow-gpu 和 keras。

2.2 VMD 分解

为了降低原始负荷数据的随机性和非线性问题带来的影响,需要对原始负荷数据进行 VMD 分解,分解后的结果如图 4 所示,取其中 200 组分解结果如图 5 所示,观察图 5 中的模态 4 和模态 5,其中心频率已经相近,当选取 $K > 5$ 时,后续中心频率十分接近,判断为过度分解。






图 4 原始数据 VMD 分解




图 5 200 组分解结果

本文通过计算分解子序列重组后信号与原始信号之间的失真程度来确定分解参数,其中经 VMD 分解后数据失真程度如表 1 所示。通过表 1 中实验 1、2、3 的失真程度对比可以确定模态数 K 选取为 5;根据实验 4、5、6、7 确定在分解后失真程度相近时选取更大的惩罚函数 $\alpha=900$;根据实验 6、8、9 确定在失真程度相近时,选取更小的噪声容忍度 $\tau=0.3$,以确保信号在数据不失真的情况下尽可能分解,降低数据的复杂度。

表 1 VMD 分解数据失真程度

实验	参数设置	RMSE	MAE
1	$K=4, \alpha=1000, \tau=0.3$	6.559	5.065
2	$K=5, \alpha=1000, \tau=0.3$	1.757	1.329
3	$K=6, \alpha=1000, \tau=0.3$	1.911	1.404
4	$K=5, \alpha=1500, \tau=0.3$	14.907	11.026
5	$K=5, \alpha=1200, \tau=0.3$	5.586	4.082
6	$K=5, \alpha=900, \tau=0.3$	0.503	0.503
7	$K=5, \alpha=600, \tau=0.3$	0.503	0.503
8	$K=5, \alpha=900, \tau=0.2$	2.940	2.189
9	$K=5, \alpha=900, \tau=0.4$	0.503	0.503

2.3 VMD-COSA-MTCN-FC 网络结构及实验

本文采用 VMD-COSA-MTCN-FC 网络对负荷数据进行预测。网络主要由 VMD 分解模块、COSA-MTCN 网络训练模块和 FC 模态融合模块 3 部分组成。输入负荷数据通过 VMD 分解模块获得 K 个模态分量。在 COSA-MTCN 模块中,对应每一个模态分量,选取对应其中心频率的时间尺度 $a、b、\dots、k$,并根据各模态分量各自对应的的时间尺度送入 TCN 网络中进行训练,对学习率采用余弦退火优化,最后输出 K 个模态分量的预测结果。模态分量的预测结果将输出到 FC 模态融合模块中,FC 网络将 K 个预测结果作为输入层进行训练,通过隐层后在输出层输出训练结果,即为对原始负荷数据的负荷预测。

2.4 实验方法及参数确定

电力负荷数据存在随机性和周期性,本文通过实验确定每一种网络的最优时间长度。共选择 10 种方法与本文方法 (VMD-MTCN-COSA-FC) 进行对比实验:1) 反向传播神经网络 (BP); 2) LSTM; 3) 门控循环单元 (GRU); 4) SVM 中的支持向量回归 (SVR); 5) TCN; 6) 基于经验模态分解的时域卷积网络 (EMD-TCN); 7) 基于变分模态分解的时域卷积网络 (VMD-TCN); 8) 基于变分模态分解和余弦退火优化的长短时记忆神经网络 (VMD-LSTM-COSA); 9) 基于变分模态分解和余弦退火优化的时域卷积网络 (VMD-TCN-COSA); 10) 基于变分模态分解和余弦退火优化的多尺度时域卷积网络 (VMD-MTCN-COSA)。

每种方法的隐层参数、时间尺度以及激活函数的选取如表 2 所示,本文 TCN 膨胀系数采用 [1,2,4,8],网络优化器均采用 Adam, Dropout 取 0.1,学习率选择 0.001,采用余弦退火优化的网络学习率范围为 0.01~0.000 1,网络训练轮次均为 300,SVR 中其他参数采用 Scikit-learn 中默认参数。

表 2 实验参数

实验名称	隐层参数	时间尺度	激活函数
BP	[16,32,16]	16	Linear
LSTM	75	5	Linear
GRU	75	5	Linear
SVM(SVR)	\	16	Gaussian
TCN	64	18	ReLU
EMD-TCN	64	18	ReLU
VMD-TCN	64	18	ReLU
VMD-LSTM-COSA	75	5	Linear
VMD-TCN-COSA	18	18	ReLU
VMD-MTCN-COSA	64	[18,20,22,24,18]	ReLU
VMD-MTCN-COSA-FC	64	[18,20,22,24,18]	ReLU

3 实验结果与分析

3.1 TCN 网络训练

将实验数据送入网络中进行训练和预测, 并用 3 种评价指标 RMSE、MAE、R2 进行评价, 其实验结果如表 3 所示。为了说明各结构的优越性, 将表 3 中后 6 种方法 EMD-TCN, VMD-TCN, VMD-LSTM-COSA, VMD-TCN-COSA, VMD-MTCN-COSA 以及本文方法的预测结果进行图表分析, 并对各实验进行误差分析。由表 3 的实验结果可以看出, 采用 TCN 方法进行预测相较于其他 4 种传统预测方法 (BP, LSTM, GRU, SVR), RMSE 和 MAE 的误差有一定程度的下降, 说明 TCN 网络预测效果更好。

表 3 实验结果

实验名称	RMSE	MAE	R2
BP	69.248	41.953	0.650
LSTM	68.279	46.586	0.507
GRU	65.365	45.370	0.543
SVM(SVR)	67.478	41.982	0.661
TCN	63.303	37.581	0.679
EMD-TCN	51.281	34.306	0.789
VMD-TCN	12.587	10.274	0.988
VMD-LSTM-COSA	13.495	10.906	0.984
VMD-TCN-COSA	10.16	7.569	0.991
VMD-MTCN-COSA	8.864	6.568	0.993
VMD-MTCN-COSA-FC	8.107	5.742	0.995

3.2 不同结构预测结果

1) VMD 分解结构预测结果

将表 3 中 TCN、EMD-TCN 和 VMD-TCN 的实验结果进行对比, 可以发现采用 VMD 方法对原始数据进行分解, 其 RMSE 下降明显。图 6 为不同分解方法的预测结果, 可以看出经 VMD 分解预测结果更贴近真实值, 说明 VMD 分解可有效降低数据的随机性及非线性的影响, 提升预测精度。




图 6 不同分解方法的预测结果

2) 余弦退火优化结构预测结果

对表 3 中的 VMD-TCN 和 VMD-TCN-COSA 方法的实验结果进行对比, 发现采用余弦退火优化方法的预测结果 MAE 下降了 26%, R2 提升 0.3%, 图 7 为网络经 COSA 优化后预测结果, 可以看出, 经过 COSA 优化的方法预测曲线拟合度更高, 验证了采用余弦退火对 TCN 网络进行优化, 网络能够收敛于更优解。




图 7 COSA 优化后预测结果

3) 多尺度结构预测结果

对表 3 中的 VMD-TCN-COSA 和 VMD-MTCN-COSA 方法的实验结果进行对比, 可以看到利用多尺度进行预测其预测结果 RMSE 下降了 13%; 图 8 为单一尺度和多尺度预测结果, 观察图 8 可看出多尺度的预测误差相较于单一尺度更小, 说明多尺度的 TCN 网络有着更强的非线性表征能力, 能够更有效地拟合输入和输出数据之间的非线性关系, 更好地表征时域上的特征。




图 8 不同尺度预测结果

4) 全连接融合结构预测结果

对表 3 中传统方法 (VMD-LSTM-COSA) 以及

VMD-MTCN-COSA 的实验结果与本文方法 (VMD-MTCN-COSA-FC) 的实验结果进行对比, 可知本文方法相较于传统方法 RMSE 下降了 40%, 曲线拟合程度提升 1.1%; 相较于未全连接融合的方法表现也更为优异。图 9 为全连接融合以及传统方法的预测结果, 由图 9 可知本文方法相较于其他两种方法能够更好的拟合真实的曲线, 验证了通过全连接网络对多尺度预测结果进行加权融合, 预测结果能够考虑到模态在融合时的相关性以及各自模态的重要程度, 能够进一步降低预测误差; 说明了本文方法相较于传统预测方法预测表现更为优异。




图 9 全连接融合与传统方法预测结果

3.3 不同方法预测误差

为了进一步对比表 3 中后 6 种实验方法, 随机选取连续的 15 个预测点计算平均预测误差, 如图 10 所示, 本文方法的平均预测误差为 0.332%, 传统方法平均预测误差为 1.35%, 说明本文方法有更高的预测精度, 大多数预测点的预测误差相较其他方法更小。预测曲线的拟合程度更高, 也说明了本文所提结构用于短期电力负荷预测中可有效降低预测误差。

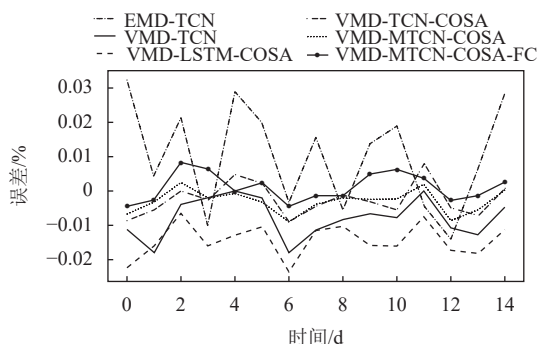


图 10 各实验预测误差

3.4 家庭数据集预测结果

为了验证本文方法有较强的泛化性能, 更换一个更大的家庭用电数据集, 该数据集以分钟为采样频率, 共 7 维 20 万组数据, 包括有功功率、无功

功率、电压等属性, 选取其中的 10000 组有功功率数据进行预测实验。分别采用传统方法 (VMD-LSTM-COSA) 和本文方法 (VMD-MTCN-COSA-FC) 进行预测, 实验结果如表 4 所示。从表 4 中可以看出本文方法相较于传统方法 RMSE 降低了 23%; MAE 降低了 20%; R2 提升 1.1%。家庭用电数据集预测结果如图 11 所示, 通过图 11 可以看到本文方法相较于传统方法可以更好地拟合真实曲线, 说明本文方法对不同时间尺度的特征都有较好的表征能力, 对不同时间尺度和不同数据量的数据集都有较高的预测精度, 较强的泛化能力及较好的预测结果。

表 4 家庭用电数据集实验结果

实验名称	RMSE	MAE	R2
VMD-LSTM-COSA	0.224	0.152	0.973
VMD-MTCN-COSA-FC	0.172	0.121	0.984




图 11 家庭用电数据集预测结果

4 结束语

本文提出了一种基于变分模态分解和时域卷积网络的多尺度短期电力负荷预测方法。利用变分模态分解电力负荷数据, 可以有效降低数据的复杂度, 解决数据的随机性和非线性等问题。并且构建多尺度的 TCN 网络用于子序列的训练, 通过 TCN 网络充分考虑时域特征, 灵活调整记忆长短, 再利用多尺度进行训练, 学习数据之间的非线性映射关系, 更好表征时域特征, 在此基础上引入余弦退火优化, 提升模型精度。最后利用全连接的新型融合结构, 充分考虑子序列之间的相关性以及自身序列的重要程度, 实现对电力负荷预测精度的提升。通过多组对比实验以及不同的数据集, 验证了本文方法具有较高的预测精度, 相较于传统方法提升了曲线拟合程度, 降低了预测误差。

后续还可以将该研究方法应用在更高数据维度

或更多领域上,也可以利用其他优化算法对网络以及分解的参数进行优化,从而减少训练时间,降低模型复杂度。

参 考 文 献

- [1] ELATTAR E E, SABIHA N A, ALSHAREF M, et al. Short term electric load forecasting using hybrid algorithm for smart cities[J]. *Applied Intelligence*, 2020, 50: 3379-3399.
- [2] DENG Z, WANG B, XU Y, et al. Multi-scale convolutional neural network with time-cognition for multi-step short-term load forecasting[J]. *IEEE Access*, 2019, 7: 88058-88071.
- [3] JEONG D, PARK C, KO Y M. Short-term electric load forecasting for buildings using logistic mixture vector autoregressive model with curve registration[J]. *Applied Energy*, 2021, 282: 116249.
- [4] NEPAL B, YAMAHA M, YOKOE A, et al. Electricity load forecasting using clustering and ARIMA model for energy management in buildings[J]. *Japan Architectural Review*, 2020, 3(1): 62-76.
- [5] 张淑清, 宿新爽, 陈荣飞, 等. 基于变分模态分解和FABP的短期电力负荷预测[J]. *仪器仪表学报*, 2018, 39(4): 67-73.
- ZHANG S Q, SU X S, CHEN R F, et al. Short-Term load forecasting based on the VMD and FABP[J]. *Chinese Journal of Scientific Instrument*, 2018, 39(4): 67-73.
- [6] 王瑞, 闫方, 逯静, 等. 运用 Dropout-LSTM 模型的新冠肺炎趋势预测[J]. *电子科技大学学报*, 2021, 50(3): 414-421.
- WANG R, YAN F, LU J, et al. COVID-19 trend forecasting by using dropout-LSTM model[J]. *Journal of University of Electronic Science and Technology of China*, 2021, 50(3): 414-421.
- [7] JIN Y, GUO H, WANG J, et al. A hybrid system based on LSTM for short-term power load forecasting[J]. *Energies*, 2020, 13(23): 6241.
- [8] ZHANG X, WANG J, ZHANG K. Short-term electric load forecasting based on singular spectrum analysis and support vector machine optimized by Cuckoo search algorithm[J]. *Electric Power Systems Research*, 2017, 146: 270-285.
- [9] 李莉, 杜丽霞, 张子柯. 基于多变量 LSTM 神经网络的澳大利亚大火预测研究[J]. *电子科技大学学报*, 2021, 50(2): 311-316.
- LI L, DU L X, ZHANG Z K, et al. Multivariable LSTM neural network model for australia fire prediction[J]. *Journal of University of Electronic Science and Technology of China*, 2021, 50(2): 311-316.
- [10] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[EB/OL]. [2021-09-22]. <https://arxiv.org/pdf/1803.01271.pdf>.
- [11] ZHENG H, YUAN J, CHEN L. Short-Term load forecasting using EMD-LSTM neural networks with a Xgboost algorithm for feature importance evaluation[J]. *Energies*, 2017, 10(8): 1168.
- [12] 刘雨薇. 基于 VMD 和改进 LSTM 的短期电力负荷预测研究[D]. 武汉: 湖北工业大学, 2020.
- LIU Y W. Research on short-term power load forecasting based on VMD and improved LSTM[D]. Wuhan: Hubei University of Technology, 2020.
- [13] YIN L, XIE J. Multi-Temporal-Spatial-Scale temporal convolution network for short-term load forecasting of power systems[J]. *Applied Energy*, 2021, 283: 116328.
- [14] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. *IEEE Transactions on Signal Processing*, 2013, 62(3): 531-544.
- [15] ZHANG Z, HONG W C, LI J. Electric load forecasting by hybrid self-recurrent support vector regression model with variational mode decomposition and improved cuckoo search algorithm[J]. *IEEE Access*, 2020, 8: 14642-14658.
- [16] 李滨, 陆明珍. 考虑实时气象耦合作用的地区电网短期负荷预测建模[J]. *电力系统自动化*, 2020, 44(17): 60-68.
- LI B, LU M Z. Short-Term load forecasting modeling of regional power grid considering real-time meteorological coupling effect[J]. *Automation of Electric Power Systems*, 2020, 44(17): 60-68.
- [17] WANG Y, CHEN J, CHEN X, et al. Short-Term load forecasting for industrial customers based on TCN-LightGBM[J]. *IEEE Transactions on Power Systems*, 2020, 36(3): 1984-1997.

编辑 税红