

基于2D-VMD和ConvLSTM的电力负荷图像化短期预测方法

李承皓^{1,2}, 杨永标^{1,2}, 宋嘉启³, 张翔颖⁴, 徐青山^{1,2}

(1. 东南大学电气工程学院, 南京 210096; 2. 南京应用数学中心, 南京 211135; 3. 南瑞集团有限公司(国网电力科学研究院有限公司), 南京 211106; 4. 南瑞工程技术有限公司南京分公司, 南京 211106)

摘要: 电力负荷预测受到诸多不确定性事件的影响, 因此准确地预测负荷一直是行业内研究的重点方向。针对传统方法在对短期电力负荷预测精度较低的问题, 给出一种基于二维变分模态分解(two-dimensional variational mode decomposition, 2D-VMD)和卷积长短期记忆神经网络(convolutional long short-term memory, ConvLSTM)的电力负荷图像化短期预测方法。首先采用格拉姆角场方法(Gramian angular fields, GAF)将预处理后的负荷数据转换为一组格拉姆角场图像, 然后通过2D-VMD将这组图像各自分解成一系列不同中心频率的子模态并按中心频率分类, 使用ConvLSTM神经网络对不同模态图像组进行预测, 最终将预测结果重构并逆操作得到负荷预测值。预测结果表明此方法提高了短期负荷预测的精度, 为电力负荷预测提供了新方法。

关键词: 电力系统; 负荷预测; 格拉姆角场; 二维变分模态分解; ConvLSTM神经网络

A Short-Term Power Load Visualization Forecasting Method Based on 2D-VMD and ConvLSTM

LI Chenghao^{1,2}, YANG Yongbiao^{1,2}, SONG Jiaqi³, ZHANG Xiangying⁴, XU Qingshan^{1,2}

(1. School of Electrical Engineering, Southeast University, Nanjing 210096, China; 2. Nanjing Center for Applied Mathematics, Nanjing 211135, China; 3. NARI Group Corporation, State Grid Electric Power Research Institute Co., Ltd., Nanjing 211106, China; 4. Nanjing Branch of Nanrui Engineering Technology Co., Ltd., Nanjing 211106, China)

Abstract: Power load forecasting is influenced by many uncertain events, so accurately predicting load has always been a key research direction in the industry. In response to the problem of low accuracy of traditional methods in short-term power load forecasting, a short-term power load visualization forecasting method is proposed based on two-dimensional variational mode decomposition (2D-VMD) and convolutional long short term memory neural networks (ConvLSTM). Firstly, the Gramian angular fields (GAF) method is used to convert the preprocessed load data into a set of Gram angular field images, and then the images are decomposed into a series of sub-modes with different center frequencies through 2D-VMD and classified according to the center frequencies. ConvLSTM neural network is used to predict the image groups with different modes. Finally, the prediction results are reconstructed and inversely operated to obtain the load prediction values. The prediction results indicate that this method improves the accuracy of short-term load forecasting and provides a new method for power load forecasting.

Key words: power system; load forecasting; Gramian angular field; two dimensional variational mode decomposition; ConvLSTM neural network

0 引言

随着用电量快速增长,电力装机量不断扩张,为了建设统一而强大的智能电网,发电企业和电力部门需要准确了解负荷的变化规律和发展趋势,确保电网的安全性和高效运营。由于电能目前无法大规模存储,电力的生产必须与消费相匹配。因此,准确的电力负荷预测对于保障电网的安全运行、实现科学发电、调度和配电具有重要意义^[1-2]。电力负荷预测作为分析供需形势的关键点,有利于电力供应稳定^[3-4]。电力负荷短期预测精准度越高,对各电力要素协调调度、削峰填谷,保障电网稳定运行的指导效果越好^[5-6]。

电力负荷短期预测目前已经发展出了很多分支,主要预测未来某段时间内选取的各时刻点负荷值。短期负荷预测的一大特征就是它在不同的时间维度上均存在周期性,可以看到考虑这类特性的预测方法的结果都很好^[7]。常用预测方法能分成人工智能预测法、数学统计预测法及混合模型。混合模型又包括用多种方法分别预测后计算最终结果和二先分解负荷再分别预测模态分量(intrinsic mode function, IMF),最后加和求得预测结果^[8]。其中人工智能预测法是目前电力负荷预测的热门方向,相对于数学统计预测法虽然仿真时间变长,但是较之精度的提升幅度仍然是可以接受的^[9],譬如LSTM神经网络就常常被用于预测电力负荷^[10]。文献[11]中也利用了改进的BP神经网络对电力负荷进行预测,但单个模型的精度仍然和混合模型有所差距,因此需要用到两种模型或多种模型的混合来进一步提高预测精度。考虑到电力负荷时序性高,可以利用信号分析方法中的模态分解对数据进行处理以进一步提高后续预测的精度^[12]。目前最常用在负荷预测上的分解方法有小波变换分解(wavelet transform, WT)、经验模态分解(empirical mode decomposition, EMD)和变分模态分解(variational nodal decomposition, VMD)。其中小波变换存在难以选取合适的基函数和可行的分解层数的问题,而EMD则存在模态混叠现象,综合考虑后使用VMD来避免以上问题^[13-14]。

对于负荷序列数据,采用图像处理相较于采用时间序列处理更易于人们的直觉理解和判断,因此越来越多的研究者将目光投向了负荷序列图像化后预测。当下许多深度学习模型输入是图像矩阵,不能直接输

入时序数据。所以需先将负荷数据转化为图像,才能使用图像处理相关的深度学习模型分析负荷数据。文献[15-16]均提出将时序数据采取多种图像编码方式,其中有GAF求和/差分场和马尔可夫转换场(Markov transition fields, MTF)。GAF可以将时间序列数据转换成图像的形式,便于直观地观察数据之间的关系和模式,并且保留了时间序列数据的相位信息,适用于非线性和周期性数据,此外它还适用于各种时间序列长度,可以处理不同长度的时间序列。而MTF方法对于非线性和周期性数据的处理能力相对较弱,可能无法捕捉到更复杂的时间序列模式,此外还需要定义转移概率的计算方法,不同的方法可能会导致不同的结果。因此文中选取格拉姆差分场对负荷序列进行图像编码。文献[17-18]都先将时序数据进行适当处理后,根据编码规则将其转化成二维矩阵,但并未考虑到图像化后仍包含负荷数据的特性进行分析。以上这些研究都没有结合时序负荷数据的分解方法对图像进行分解,增加了后续提取图像特征进行预测的难度。

综上所述,目前研究大都只对一维负荷序列进行分解后预测,或是对一维负荷序列图像化后进行预测,并未考虑到负荷图像化后仍然包含负荷数据的特性^[19-20]。2015年Dragomiretskiy^[21]等提出二维变分模态分解算法,该算法将处理一维信号扩展到了二维的图像上,目前常用于图像去噪、增强,而本文根据其特性将它运用到负荷图像分解上尝试进一步提升负荷预测的精度,因为它的分解结果具备描述图中对象全局重点以及局部细节信息的能力^[22]。因此文章先结合2D-VMD方法对图像进行分解后,再使用ConvLSTM进行预测。

分析上述文献后为提高电力负荷短期预测的精度,本文提出一种基于2D-VMD和ConvLSTM的电力负荷图像化短期预测方法。使用格拉姆角场将一维历史负荷数据转换为二维图像,后续得以使用卷积神经网络对数据进行学习。然后用2D-VMD方法分解原始图片,并按中心频率进行分组。同组模态分量经过ConvLSTM神经网络挖掘隐藏局部特征和时空特征,得到各模态预测图像。将其融合后再由图像逆转回时间序列,得到未来电力负荷预测结果。最后依托江苏某地区负荷数据进行预测,表明本文所提方法在预测台区短期电力负荷时,相比于传统的长短期记忆(long Shortterm memory, LSTM)、反

向传播(back propagation, BP)神经网络预测, 或者是基于VMD、EMD分解方法分别预测的精度要更高。

1 基于格拉姆角场的序列数据图像化处理

以文献[23]中选择格拉姆求差场(Gramian angular difference fields, GADF)将时间序列编码为图像, 这可以让卷积神经网络更有效的提取特征。本文采用格拉姆角场, 它使用极坐标系来表现时间序列的^[23]。可以通过以下几个步骤描述时序数据图像化过程。

1) 规范化

有时序数据 $X = \{x_1, x_2, x_3, \dots, x_n\}$, 将它归一化到区间 $[-1, 1]$, 归一化后记为 $\tilde{X} = \{\tilde{x}_1, \tilde{x}_2, \tilde{x}_3, \dots, \tilde{x}_n\}$, 时序值记为 $\tilde{x}_i$ 。此时 Gram Matrix 如下所示。

$$G = \begin{bmatrix} \cos(\phi_{1,1}) & \cos(\phi_{1,2}) & \dots & \cos(\phi_{1,n}) \\ \cos(\phi_{2,1}) & \cos(\phi_{2,2}) & \dots & \cos(\phi_{2,n}) \\ \dots & \dots & \dots & \dots \\ \cos(\phi_{n,1}) & \cos(\phi_{n,2}) & \dots & \cos(\phi_{n,n}) \end{bmatrix} \quad (1)$$

式中 $\phi_{i,j}$ 为向量 i 与向量 j 之间的夹角。

2) 极坐标转换

将规范化后的值转化为极坐标, 转换公式如下所示。

$$\begin{cases} \phi_i = \arccos \tilde{x}_i \\ r_i = \frac{t_i}{N} \end{cases} \quad (2)$$

式中: $t_i \in N$, 代表了 x_i 的时间戳, N 为时序数据中时间点数量, 表示将极坐标单位长度 N 等分, 每个时序点数据都含规范化值 $\tilde{x}_i$ 和时序位置 t_i 两个信息, 没有损失任何信息, 极轴 r_i 和极角 ϕ_i 分别保留了时间和数值上的关系。

3) 自定义内积

GAF定义了自己的内积来表示Gram矩阵中的角度定义相关程度, 本文使用GADF编码, 通过两点间三角差更好地从角度视角识别不同时间间隔下的时间相关性, $\langle x_1, x_2 \rangle = \sin(\phi_1 - \phi_2)$ 。然后定义为:

$$G = \begin{bmatrix} \sin(\phi_1 - \phi_1) & \sin(\phi_1 - \phi_2) & \dots & \sin(\phi_1 - \phi_n) \\ \sin(\phi_2 - \phi_1) & \sin(\phi_2 - \phi_2) & \dots & \sin(\phi_2 - \phi_n) \\ \dots & \dots & \dots & \dots \\ \sin(\phi_n - \phi_1) & \sin(\phi_n - \phi_2) & \dots & \sin(\phi_n - \phi_n) \end{bmatrix} \quad (3)$$

式中 ϕ_i 为第 i 序列的角度值, 对于一个原始时间序列长度为 n 的电力负荷时间序列, 通过GADF编码得到尺寸为 $n \times n$ 的数值矩阵。下面选取某一天(96点, 15 min采样一次)的电力负荷数据进行效果展示, 如图1—2所示。




图1 负荷数据原始序列

Fig. 1 Raw sequence of load data




图2 GADF 编码

Fig. 2 GADF encoding

2 基于2D-VMD和ConvLSTM的图像预测

2.1 二维变分模态分解

二维变分模态分解和一维的有很多相似之处, 不仅保持数据保真度, 还最小化分解后的模态分量带宽。为了完成从一维到二维的延伸, 首先需要定义二维解析信号^[21, 24]。

在一维中是通过将每个模态进行希尔伯特黄变换后将其作为虚部得到一维解析信号的。延伸到二维后

将频域的一半平面设成0, 它相当于一个矢量 ω_k , 得到频域里二维解析信号 $u_{AS,k}(\mathbf{x})$:

$$u_{AS,k}(\omega) = \begin{cases} 2u_k(\omega), & \langle \omega, \omega_k \rangle > 0 \\ u_k(\omega), & \langle \omega, \omega_k \rangle = 0 \\ 0, & \langle \omega, \omega_k \rangle < 0 \end{cases} \quad (4)$$

式中: $u_k(\omega)$ 为一维解析信号; ω 为频谱值。有上述傅里叶变换特性的二维解析信号如式(5)所示。

$$u_{AS,k}(\mathbf{x}) = u_k(\mathbf{x}) * \left(\delta(\langle \mathbf{x}, \omega_k \rangle) + \frac{j}{\pi \langle \mathbf{x}, \omega_k \rangle} \right) \delta(\langle \mathbf{x}, \omega_{k,\perp} \rangle) \quad (5)$$

式中: *符号表示卷积运算, 并且变换是可以分离的;

$\frac{j}{\pi \langle \mathbf{x}, \omega_k \rangle}$ 为希尔伯特变换的核函数, 用于生成解析信号的虚部; $\delta(\langle \mathbf{x}, \omega_{k,\perp} \rangle)$ 为Dirac脉冲函数。

二维变分模态分解类似处理一维信号, 本质也是个变分问题的求解。设输入信号为 $f(x)$, 分解后得 k 个模态分量 $u_k(t)$, 各模态分量对应的中心频率为 ω_k 。最小化所有模态分量带宽和, 得到约束变分模型:

$$\begin{aligned} \min_{u_k, \omega_k} & \left\{ \sum_k \alpha_k \left\| \nabla [u_{AS,k}(\mathbf{x}) e^{-j(\omega_k, \mathbf{x})}] \right\|_2^2 \right\} \\ \text{s.t. } & \forall \mathbf{x}: \sum_k u_k(\mathbf{x}) = f(\mathbf{x}) \end{aligned} \quad (6)$$

式中 α_k 为第 k 个模态频率的二次惩罚因子。

为解决上述问题, 通过引入拉格朗日乘子 λ 、二次惩罚因子 α 将其转为非约束变分问题, 得到拉格朗日扩展式:

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \sum_k \alpha_k \left\| \nabla [u_{AS,k}(\mathbf{x}) e^{-j(\omega_k, \mathbf{x})}] \right\|_2^2 + \\ & \left\| f(\mathbf{x}) - \sum_k u_k(\mathbf{x}) \right\|_2^2 + \left\langle \lambda(\mathbf{x}), f(\mathbf{x}) - \sum_k u_k(\mathbf{x}) \right\rangle \end{aligned} \quad (7)$$

则非约束问题表示为:

$$\min_{u_k, \omega_k} \max_{\lambda} \mathcal{L}(\{u_k\}, \{\omega_k\}, \{\lambda\}) \quad (8)$$

引入乘法算子交替方向法对该问题进行优化, 最终得到二维解析信号的 k 个模态分量。

分解方法具体过程如下。

1) 初始化 $\{\hat{u}_k^0\}$, $\{\hat{\omega}_k^0\}$, $\{\hat{\lambda}^0\}$, 其中 $\{\hat{u}_k^0\}$ 为初始的模态分量, $\{\hat{\omega}_k^0\}$ 为初始的频域中心频率, $\{\hat{\lambda}^0\}$ 为初始的拉格朗日乘子并设置 n 初始为0;

2) 循环更新 u_k 和 ω_k , 公式如下:

$$\begin{cases} \omega_k^{n+1} = \frac{\int_{\mathbb{R}^2} \omega |\tilde{u}_{AS,k}^{n+1}(\omega)|^2 d\omega}{\int_{\mathbb{R}^2} |\tilde{u}_{AS,k}^{n+1}(\omega)|^2 d\omega} \\ u_k^{n+1}(\mathbf{x}) = \mathcal{R}(\mathcal{F}^{-1} \tilde{u}_{AS,k}^{n+1}(\omega)) \end{cases} \quad (9)$$

式中: $\mathcal{R}$ 、 $\mathcal{F}^{-1}$ 分别为提取实数部分和逆傅里叶变换; $\tilde{u}_{AS,k}^{n+1}(\omega)$ 为第 $n+1$ 次迭代时解析信号的频域表示; $\mathbb{R}^2$ 为二维实数空间。

(1) 更新乘法算子 λ :

$$\hat{\lambda}^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + \tau (\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega)) \quad (10)$$

式中: $\hat{\lambda}^{n+1}(\omega)$ 为第 $n+1$ 次迭代中频率 ω 处的更新后的拉格朗日乘数; τ 为步长更新系数; $\hat{f}(\omega)$ 为频域表示; $\hat{u}_k^{n+1}(\omega)$ 为第 k 个分量在频率 ω 处的频域表示。

(2) 直到 $\frac{\sum_k \|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < K\epsilon$, 停止迭代, 式中:

$\hat{u}_k^{n+1}$ 为第 k 个分量的频域表示; $K\epsilon$ 为预先设置的阈值。

和研究VMD一样, 模态分量数 k 和惩罚因子 α 仍是十分重要的参量。如果 k 值太小, 很多高频信息不能很好地被分割, 叠加到一张子模状态下, 从而造成后续预测效果不佳, k 和 α 值的设定是否合理将会对最后的预测精度产生重要的影响。经过多轮试验后得出结论, 相较于取其他值, 当 $k=3$ 且 $\alpha=116$ 时, 分解后融合图像还原度很高并且后续预测精度也可以取得很好的效果。使用结构相似性(structural similarity, SSIM)和相关系数(correlation coefficient, CC)来评价分解效果。两者计算公式如下。


1) SSIM: 作为评价图像质量的模型, 从结构、对比度、亮度多角度评价图像的失真。取值范围一般是 $[0, 1]$, 值越接近1, 表示图像质量越高。

$$\text{SSIM}(x, y) = \frac{[2\mu_x \mu_y + (k_1 L)^2][2\sigma_{xy} + (k_2 L)^2]}{[\mu_x^2 + \mu_y^2 + (k_1 L)^2][\sigma_x^2 + \sigma_y^2 + (k_2 L)^2]} \quad (11)$$


式中: μ_x 、 μ_y 分别为两图均值; σ_x 、 σ_y 为两图标准差; k_1 、 k_2 为两个标量常数; L 为像素值的动态范围; σ_{xy} 为两幅图像协方差。

2) CC: 融合图像评价指标, 使用皮尔逊相关系数。


以图1为例, 对其进行分解, 得到图3(还原后SSIM: 0.9865, CC: 0.9983)。



(a) IMF1



(b) IMF2



(c) IMF3

图3 2D-VMD分解效果展示

Fig. 3 2D-VMD decomposition effect display

2.2 ConvLSTM神经网络

ConvLSTM神经网络是LSTM神经网络的一类变体,它结合了LSTM处理时间序列预测问题效果显著和卷积网络提取特征的优势,有效提取时空特征,并采用多步时空预测^[25-27]。本文利用它寻找电力负荷时序数据的特征。

ConvLSTM神经网络能很好地解决LSTM不太适用于带有空间性质的数据上这个问题,通过把LSTM中的乘积计算变为卷积,更好地压缩数据特征,获取关键特征,并更好表征局部特征。LSTM神经网络采用全连接方式去获取全部数据特征,ConvLSTM神经网络则采用卷积操作对特征进行压缩提取,保证最大化关键特征占比,公式为:

$$\begin{cases} i_t = \sigma(W_{xi} * X_t + W_{il} * H_{t-1} + W_{cl} \circ C_{t-1} + b_i) \\ f_t = \sigma(W_{xf} * X_t + W_{fl} * H_{t-1} + W_{cf} \circ C_{t-1} + b_f) \\ C_t = f_t \circ C_{t-1} + i_t \circ \tanh(W_{xc} * X_t + W_{hl} * H_{t-1} + b_c) \\ o_t = \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + W_{co} \circ C_t + b_o) \\ H_t = o_t \circ \tanh(C_t) \end{cases} \quad (12)$$

式中: * 为卷积运算; $\circ$ 为哈达玛乘积运算; σ 为sigmoid激活函数; i_t 为输入状态的保留概率; f_t 为遗忘门状态的保留概率; W_{xi} 、 W_{il} 、 W_{cl} 、 W_{xf} 、 W_{fl} 、 W_{cf} 、 W_{hl} 、 W_{xc} 、 W_{ho} 、 W_{co} 为网络权重参数矩阵; C_t 、 C_{t-1} 为存储单元张量; o_t 为输出门状态的保留概率; X_t 为输入张量; H_t 、 H_{t-1} 为隐藏状态张量; b_i 、 b_f 、 b_c 、 b_o 均为偏置。

2.3 预测方法的总体框架

本文通过实验探索,发现了先将图像进行分解,对模态分量分别预测后融合得到的预测结果更为精确。结合卷积网络在处理图像特征方面有很强的提取能力,还有模态分解对具有非线性和非平稳性电力负荷优秀分解效果,将时间序列通过格拉姆角场转换为二维图像,构建了GAF与多输入2D-VMD-ConvLSTM网络组合的预测方法。该方法的流程如图4所示。

3 算例

3.1 数据集及评价指标

本文的数据集来自江苏某地区的电力负荷实测数据,选取其中2020年8月30日到2021年8月30日的负荷为训练数据,每隔15 min采样一次。在使用格




图4 GAF与2D-VMD-ConvLSTM方法流程图

Fig. 4 Flow chart of GAF and 2D-VMD-ConvLSTM methods

拉姆角场前, 将其缩放到 $[-1, 1]$ 。

本文选取以下评价指标对预测精度进行评价: 均方根误差(root mean square error, RMSE, 其值用 R 表示)、平均绝对百分比误差(mean percentage error, MAPE, 其值用 M 表示)和决定系数(R-squared, R^2 , 其值用 R^2 表示)。指标定义如下:

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

$$M = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (14)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (15)$$

式中: y_i 为实际值; $\hat{y}_i$ 为预测值; n 为样本数量。

3.2 2D-VMD和ConvLSTM模型参数配置

关于2D-VMD和ConvLSTM具体配置设计如表1和2所示。

经过如上参数设置后的2D-VMD分解效果很好, 图像分解前后观察SSIM和CC指标, 基本超过0.95

表1 2D-VMD参数设置

Tab. 1 2D-VMD parameter settings

参数名称	数值
模态数 k	3
惩罚系数 α	116
收敛容差 t_{ol}	3×10^{-6}
对偶项的梯度下降学习率 t_{au}	0.25
最大迭代次数 T	100

表2 ConvLSTM模型参数设置

Tab. 2 ConvLSTM model parameter settings

参数名称	数值
输入维度	1
卷积核尺寸	(3, 3)
优化器	Adam(学习率为0.001)
隐藏层节点数量	64
ConvLSTM层数	3

和0.99; 而如上设置的ConvLSTM网络参数组合会在后续预测精度上有很高的精度。

3.3 预测过程及结果

经过前文格拉姆角场图像编码将一维电力负荷数据转换为二维图像, 并经过2D-VMD分解成3组模态分量后, 分别对3组模态分量图片利用ConvLSTM进行预测。预测未来3 d的电力负荷, 本算例预测2021年8月31日到9月2日的电力负荷, GADF预测图像的IMF1、IMF2、IMF3和模态分量训练时损失函数变化如图5、6所示, 以8月31日举例。

IMF₁组损失最终为0.101 1; IMF₂组损失最终为




图5 8-31的IMF1、IMF2、IMF3预测结果展示

Fig. 5 Display of IMF1, IMF2, IMF3 predicted results on 8-31




图6 训练损失

Fig. 6 Training loss

0.004 3; IMF₃组损失最终为0.011 4。

得到预测的3个模态分量后, 对其进行融合, 得到8月31日预测电力负荷数据的GADF图像, 见图7。




图7 IMFs融合结果展示

Fig. 7 Display of IMFs fusion results

同理得到9月1—2日的IMFs预测结果进行图像融合。最后将GADF图像的数组矩阵进行逆变换, 得到3 d预测电力负荷一维时序数据, 与真实结果进行比较。为验证本文所提方法在提升预测精度上的有效性, 将 GAF-2D-VMD-ConvLSTM 与 GAF-ConvLSTM、VMD-LSTM、经离散小波变换分解重构预测(DWT-LSTM)、还有传统的LSTM和BP模型的预测结果进行比对。模型比对预测结果如表3所示, 电力负荷预测结果见图8。其实为清晰直观地展示预测结果, 图

8为各模型预测曲线图。

表3 不同模型预测评价

Tab. 3 Evaluation of prediction of different models

模型序号	预测模型	RMSE 值/ kW	MAPE 值/%	R ² 值
1	LSTM	1 542. 276	2. 98	0. 933
2	BP	1 736. 853	3. 10	0. 929
3	VMD-LSTM	977. 187	2. 42	0. 957
4	DWT-LSTM	1 064. 423	2. 48	0. 952
5	GAF-ConvLSTM	700. 194	2. 33	0. 969
6	GAF-2D-VMD-ConvLSTM	537. 129	1. 86	0. 978

从表3可以看出本文所提的GAF-2D-VMD-ConvLSTM预测模型与传统的LSTM、BP, 还有一维模态分解使用LSTM预测分量的VMD-LSTM、DWT-LSTM 和格拉姆角场变换后直接使用ConvLSTM 预测的GAF-ConvLSTM 的模型相比, RMSE 分别降低了1 005. 147 kW、1 199. 724 kW、440. 058 kW、527. 294 kW、163. 065 kW, MAPE 分别提高了 1. 12%、1. 24%、0. 56%、0. 62%、0. 47%, R² 值则分别提高了0. 045、0. 049、0. 021、0. 026、0. 009。对以上指标综合分析, 本文所提出的GAF-2D-VMD-ConvLSTM模型预测出的电力负荷与真实值拟合程度更好, 预测精度更高。




图8 多模型预测结果对比

Fig. 8 Comparison of multiple model prediction results

由图8可以看出, GAF-2D-VMD-ConvLSTM模型拟合效果更好, 再结合表3数据, 可以得到本问题提出的模型预测精度更高的结论。

4 结论

本文针对负荷预测精度问题提出了一种基于 2D-VMD 和 ConvLSTM 的电力负荷图像化短期预测方法, 将一维负荷数据经过格拉姆角场图像编码后, 先经过 2D-VMD 进行模态分解, 再对模态分量进行分组预测, 最终融合成预测 GADF 图像并逆变换回一维电力负荷预测数据。实验结果表明本文提出的 GAF-2D-VMD-ConvLSTM 预测方法有比较高的精度, 通过实验分析得出以下结论。

1) 引入 GAF 对图像进行编码, 使其能够使用图像处理方面的深度学习模型, 可以更有效地分析负荷数据。

2) 使用 2D-VMD 方法对 GADF 图像先分解后再分别预测, 充分发挥变分模态分解的优势, 提升了预测能力。

3) 本文方法在传统数据图像编码后直接进行图像预测的基础上, 对图像先进行分解以降低图像特征复杂性, 为电力负荷的预测提供了具有一定可行性的新方法。

本文目前只考虑了负荷本身, 后续将尝试把相关影响因素的数据也转为图像。此外可以改进 ConvLSTM, 使用双向网络提升, 并且使用优化算法优化 2D-VMD 的 k 和 α , 均有望进一步提升图像化负荷预测方法的准确率。

参考文献

- [1] SGN G S, SHESHADRI N C. ANN based short term load forecasting for Karnataka state demand [C]// 2022 IEEE North Karnataka Subsection Flagship International Conference (NKCon), May 27, 2022, Vijaypur, India. New York: 2022: 1-5.
- [2] 张大海, 孙锴, 和敬涵. 基于相似日与多模型融合的短期负荷预测[J]. 电网技术, 2023, 47(5): 1961-1970.
ZHANG Dahai, SUN Kai, HE Jinghan. Short-term load forecasting based on similar day and multi-model fusion [J]. Power System Technology, 2023, 47(5): 1961-1970.
- [3] 邵必林, 纪丹阳. 基于 VMD-SE 的电力负荷分量的多特征短期预测[J]. 中国电力, 2024, 57(4): 162-170.
SHAO Bilin, JI Danyang. Multi-feature short-term prediction of power load components based on VMD-SE [J]. Electric Power, 2024, 57(4): 162-170.
- [4] 张未, 余成波, 王士彬, 等. 基于 VMD-LSTM-LightGBM 的多特征短期电力负荷预测[J]. 南方电网技术, 2023, 17(2): 74-81.
ZHANG Wei, YU Chengbo, WANG Shibin, et al. Multi-featured short-term power load forecasting based on VMD-LSTM- LightGBM [J]. Southern Power System Technology, 2023, 17(2): 74-81.
- [5] 杨书强, 王涛, 檀晓林, 等. 基于长短期记忆的图像化短期电力负荷预测方法[J]. 全球能源互联网, 2023, 6(3): 282-288.
YANG Shuqiang, WANG Tao, TAN Xiaolin, et al. Image based short-term power load forecasting method using long short-term memory [J]. Journal of Global Energy Interconnection, 2023, 6(3): 282-288.
- [6] 刘亚琤, 赵倩. 基于聚类经验模态分解的 CNN-LSTM 超短期电力负荷预测[J]. 电网技术, 2021, 45(11): 4444-4451.
LIU Yahui, ZHAO Qian. Ultra-short-term power load forecasting based on cluster empirical mode decomposition of CNN-LSTM [J]. Power System Technology, 2021, 45(11): 4444-4451.
- [7] KEERTI R, AIJAZ A. Applications of big data and artificial intelligence in smart energy systems smart energy system: design and its state-of-the art technologies [M]. Denmark: River Publishers, 2023: 101-126.
- [8] MAURYA M, GOSWAMI A K. Short term wind energy forecasting using sample entropy based decomposition and deep neural network [C]// 2022 IEEE International Conference on Power Electronics, Smart Grid, and Renewable Energy (PESGRE), June 1-2, 2022, Trivandrum, India. New York: IEEE, 2022: 1-7.
- [9] 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.
- [10] ROY A D, YEAFI A. Implementation of encoder-decoder based long short-term memory network for short-term electrical load forecasting [C]//2022 4th International Conference on Sustainable Technologies for Industry 4.0 (STI), March 3-5, 2022, Dhaka, Bangladesh. New York: IEEE, 2022: 1-6.
- [11] 牛庆, 曹爱民, 陈潇一, 等. 基于花朵授粉算法和 BP 神经网络的短期负荷预测[J]. 电网与清洁能源, 2020, 36(10): 28-32.
NIU Qing, CAO Aimin, CHEN Xiaoyi, et al. Short-term load forecasting based on flower pollination algorithm and BP neural network [J]. Power System and Clean Energy, 2020, 36(10): 28-32.
- [12] SAFARI N, PRICE G C D, CHUNG C Y. Analysis of empirical mode decomposition-based load and renewable time series forecasting [C]//2020 IEEE Electric Power and Energy Conference (EPEC), July 5, 2020, Edmonton, AB, Canada. New York: IEEE, 2020: 1-6.
- [13] GUO T, ZHANG T, LIM E, et al. A review of wavelet analysis and its applications: challenges and opportunities [J]. IEEE Access, 2022(10): 58869-58903.
- [14] HOSSAIN M R, ISMAIL M T, KARIM SABA. Improving stock price prediction using combining forecasts methods [J]. IEEE Access, 2021(9): 132319-132328.
- [15] 郭琛. 基于深度学习的时间序列组合预测模型研究[D]. 南昌: 南昌大学, 2022.
- [16] 徐青山. 基于时间序列成像的集成深度神经网络的短期负荷预测研究[D]. 南昌: 南昌大学, 2021.
- [17] 刘科研, 周方泽, 周晖. 基于时序信号图像编码和生成对抗网络的配电网台区数据修复[J]. 电力系统保护与控制, 2022, 50(24): 129-136.

- LIU Keyan, ZHOU Fangze, ZHOU Hui. Missing data imputation in a transformer district based on time series imaging encoding and a generative adversarial network [J]. Power System Protection and Control, 2022, 50(24): 129 – 136.
- [18] 张淑清, 杜灵韵, 王册浩, 等. 基于格拉姆角场与改进 CNN-ResNet 的风电功率预测方法[J]. 电网技术, 2023, 47(4): 1540 – 1548.
- ZHANG Shuqing, DU Lingyun, WANG Cehao, et al. Wind power forecasting method based on GAF and improved CNN-ResNet[J]. Power System Technology, 47(4): 1540 – 1548.
- [19] 李雅婷, 肖晶, 廖良, 等. 面向视觉数据处理与分析的解耦表示学习综述[J]. 中国图象图形学报, 2023, 28(4): 903 – 934.
- LI Yating, XIAO Jing, LIAO Liang, et al. A review of disentangled representation learning for visual data processing and analysis[J]. Journal of Image and Graphics, 2023, 28(4): 903 – 934.
- [20] 张天予, 闵巍庆, 韩鑫阳, 等. 视频中的未来动作预测研究综述[J]. 计算机学报, 2023, 46(6): 1315 – 1338.
- ZHANG Tianyu, MIN Weiqing, HAN Xinyang, et al. A survey on future action anticipation in videos [J]. Chinese Journal of Computers, 2023, 46(6): 1315 – 1338.
- [21] DRAGOMIRETSKIY K, ZOZZO D. Two-dimensional variational mode decomposition [C]//Proceeding of International Workshop on Energy Minimization Methods in Computer Vision and Pattern Recognition, August 13 – 16, 2015, Hong Kong, China. Berlin: Springer, 2015: 1 – 10.
- [22] CUI Z Y, CAO Z J, YANG J Y, et al. Target recognition in synthetic aperture radar via non-negative matrix factorization [J]. IET Radar, Sonar and Navigation, 2015, 9(9): 1376 – 1385.
- [23] 张辉, 戈宝军, 韩斌, 等. 基于 GAF-CapsNet 的电机轴承故障诊断方法[J]. 电工技术学报, 2023, 38(10): 2675 – 2685.
- ZHANG Hui, GE Baojun, HAN Bin, et al. Fault diagnosis method of motor bearing based on GAF-CapsNet[J]. Transactions of China Electrotechnical Society, 2023, 38(10): 2675 – 2685.
- [24] 刘嘉敏, 彭玲, 袁佳成, 等. 基于二维变分模态分解和自适应中值滤波的图像去噪方法[J]. 计算机应用研究, 2017, 34(10): 3149 – 3152.
- LIU Jiamin, PENG Ling, YUAN Jiacheng, et al. Image denoising method based on bi-dimensional variational mode decomposition and adaptive median filtering [J]. Application Research of Computers, 2017, 34(10): 3149 – 3152.
- [25] 王俊杰, 毕利, 张凯, 等. 基于多特征融合和 XGBoost-LightGBM-ConvLSTM 的短期光伏发电量预测[J]. 太阳能学报, 2023, 44(7): 168 – 174.
- WANG Junjie, BI Li, ZHANG Kai, et al. Short-term photovoltaic generation prediction based on multi-feature fusion and XGBoost-LightGBM-ConvLSTM [J]. Acta Energetica Solaris Sinica, 2023, 44(7): 168 – 174.
- [26] VRSKOVA R, SYKORA P, KAMENCAY P, et al. Hyperparameter tuning of ConvLSTM network models [C]//2021 44th International Conference on Telecommunications and Signal Processing (TSP), April 2 – 3, 2021, Brno, Czech Republic. New York: IEEE, 2021: 15 – 18.
- [27] MOISHIN M, DEO R C, PRASAD R, et al. Designing deep-based learning flood forecast model with ConvLSTM hybrid algorithm[J]. IEEE Access, 2021(9): 50982 – 50993.

收稿日期: 2023-09-06; 网络首发日期: 2024-05-14

作者简介:

李承皓(1999), 男, 硕士研究生, 研究方向为人工智能算法在电力系统中的应用、需求响应, 220215825@seu.edu.cn;

杨永标(1978), 男, 通信作者, 高级工程师, 硕士, 研究方向为需求响应、虚拟电厂、综合能源服务, 103200017@seu.edu.cn;

宋嘉启(1997), 男, 助理工程师, 硕士, 研究方向为优化调度、负荷预测、大电网安全稳定, songjiaqi@sgepri.sgcc.com.cn。