

基于 ICEEMDAN 和 TCN-AM-BiGRU 的短期光伏功率预测^{*}

白 隆¹ 俞 碩² 高 峰² 顾晋豪¹ 徐 姣¹

(1. 南京信息工程大学自动化学院 南京 210044; 2. 无锡学院自动化学院 无锡 214105)

摘要: 光伏发电功率的准确预测对综合能源系统的安全稳定运行以及实时控制至关重要。为解决光伏功率预测过程中存在噪声干扰以及传统的单一预测模型存在预测精度较差等问题,本文提出一种基于 ICEEMDAN 和 TCN-AM-BiGRU 相结合的短期光伏功率预测模型。首先,利用皮尔逊相关系数筛选关键气象因素,通过模糊 C 均值聚类将光伏功率历史数据划分为晴天、多云和阴雨 3 种相似日;其次利用 ICEEMDAN 将历史训练集分解成若干个较为规律的子序列,并根据排列熵值进行重构;最后,通过 TCN 提取序列特征,引入注意力机制赋予不同的权重,再通过 BiGRU 进行预测,输出最终的预测结果。以某光伏电站的实际数据为例对预测模型和其他模型进行验证和分析,结果表明在晴天、多云和阴雨天气下,相比其他对比模型,所提模型准确率平均提高了 1.69%、3.58% 和 4.40%,MAE 平均降低了 57.61%、36.83% 和 40.94%,RMSE 平均降低了 56.90%、34.30% 和 36.63%,验证了本文模型的有效性和优越性。

关键词: 模态分解;相似日聚类;TCN;注意力机制;BiGRU

中图分类号: TN06; TP271 文献标识码: A 国家标准学科分类代码: 470.4047

Short-term photovoltaic power prediction based on ICEEMDAN and TCN-AM-BiGRU

Bai Long¹ Yu Bin² Gao Feng² Gu Jinhao¹ Xu Jie¹

(1. School of Automation, Nanjing University of Information Science and Technology, Nanjing 210044, China;

2. School of Automation, Wuxi University, Wuxi 214105, China)

Abstract: The accurate prediction of PV power is very important for the safe and stable operation and real-time control of the integrated energy system. In order to solve the problems of noise interference in photovoltaic power prediction and poor prediction accuracy of traditional single prediction model, a short-term photovoltaic power prediction model based on ICEEMDAN and TCN-AM-BiGRU is proposed. Firstly, the Pearson correlation coefficient was used to screen the key meteorological factors, and the historical PV power data were divided into three similar days: sunny, cloudy and rainy by fuzzy C-means clustering. Secondly, ICEEMDAN is used to decompose the historical training set into several regular subsequences and reconstruct them according to the permutation entropy. Finally, the sequence features are extracted by TCN, the attention mechanism is introduced to assign different weights, and then the prediction is made by BiGRU to output the final prediction result. Taking the actual data of a photovoltaic power station as an example, the prediction model and other models were verified and analyzed. The results showed that in sunny, cloudy and rainy weather, compared with other comparison models, the accuracy of the proposed model increased by 1.69%, 3.58% and 4.40% on average, the MAE decreased by 57.61%, 36.83% and 40.94% on average, and the RMSE decreased by 56.90%, 34.30% and 36.63% on average, which verified the effectiveness and superiority of the proposed model.

Keywords: modal decomposition; similar day clustering; TCN; attention mechanism; BiGRU

0 引言

近年来,随着能源的过度消耗,生态环境日趋恶化,环

境污染问题日益严重,不可再生能源也面临枯竭的困境^[1]。因此,世界各国都在积极地探索利用可再生能源逐步替代传统化石能源的新道路^[2]。太阳能具有取之不尽、用之不

竭、经济环保、高效稳定等优点,是最重要的可再生能源之一^[3]。由于光伏发电受多种天气因素制约,因此其发电功率具有较强的波动性和随机性。随着光伏渗透率的不断增大,这将对电力系统的安全稳定运行带来严峻的挑战^[4]。因此,设计一种精确的太阳能光伏发电功率预测方法对于确保系统的稳定性、可靠性和电力调度能力至关重要^[5]。目前,光伏预测模型大致分成 3 类,包括:物理预测、统计预测和组合预测^[6]。

物理预测方法是基于太阳能光伏系统的工作原理和光伏电池的响应特性,结合天气数据,再根据光电转换效率建立数学模型来预测光伏发电功率的输出。研究发现通过对辐照度分离与转置建模,可以显著提升模型的预测精度^[7-8]。虽然该预测方法不要大量数据,但由于某些气象因素无法测量且建模困难,在实际应用中存在适用性差、精度低等问题^[9]。

统计预测是统计学原理和时间序列分析方法,利用历史数据的统计特征和模式来进行预测。常见的统计模型包括:时间序列^[10]、回归分析^[11]等。这类预测方法的局限性主要是对于非平稳时间序列和高度非线性的时间序列是无法进行准确预测的。

组合预测方法的主要思想是利用不同预测方法或模型的优势和特点,将它们有机结合来得到更准确可靠的预测结果的方法^[12]。该类方法可以充分利用不同预测方法之间的差异,减少单个模型的局限性,并提高预测的准确性和鲁棒性。Wang 等^[13]提出了一种基于经验模态分解(empirical mode decomposition, EMD)和相关向量机的组合模型,但是 EMD 分解容易发生模态混叠,会影响模型的预测精度。朱正林等^[14]采用变分模态分解(variational mode decomposition, VMD)将光伏功率分解成子序列,再利用天鹰算法优化双向门控循环单元(bidirectional gated recurrent unit, BiGRU),但该分解方法并不是自适应分解,而是需人为设置分解次数,有可能使预测精度降低。Li 等^[15]提出了一种基于小波包分解(wavelet packet decomposition, WPD)和长短期记忆网络的短期光伏功率预测模型,由于小波包分解缺乏自适应性,因此对于高频非平稳序列的分解效果较差,在一定程度上会影响预测性能。Li 等^[16]采用了改进的自适应噪声完全集合模态分解(improved complete ensemble empirical mode decomposition with adaptive noise, ICEEMDAN)将复杂的原始数据分解为几个相对简单的子序列,相比于 EMD、WPD 和 VMD,分解效果更好。但分解后的分量波动频率差异较大,在时间序列内不同时间尺度上代表的信息不同。直接使用单一模型预测所有成分并叠加结果会产生一定的误差。

综合以上问题,本文提出一种基于 ICEEMDAN 和 TCN-AM-BiGRU 的短期光伏功率预测模型。首先对天气气象因素进行相关性分析,筛选出关键影响因素;其次采用模糊 C 均值聚类算法(fuzzy C-means, FCM)对原始数据

进行聚类,划分成 3 种相似日类型,以便于对特征的进一步挖掘。然后,采用 ICEEMDAN 分解光伏功率数据,并依据各分量的排列熵值对分量进行重构,以降低数据的复杂性、波动性以及噪声干扰。最后,融合时域卷积网络(temporal convolutional network, TCN)和 BiGRU 两个网络模型,充分利用 TCN 在处理时间序列问题的优势及 BiGRU 在捕捉序列数据的双向依赖关系的优势,并引入注意力机制给 TCN 提取的特征赋予权重,从而更好地提取光伏功率序列的特征,将各部分预测结果相加,得到最终的预测结果。

1 相关性分析

1.1 光伏发电功率影响因素分析

影响光伏发电功率的气象因素有多种,这些气象因素主要包括辐照度、环境温度、相对湿度、降雨量、风速和风向等。其中,辐照度包括总水平辐照度、漫射水平辐照度、总倾斜辐照度、漫射倾斜辐照度 4 种。然而,不同的气象因素对发电功率影响程度不同,因此,首先要从这些气象因素中筛选出对发电功率有较大影响的气象因素。为此,本文使用皮尔逊相关系数(pearson correlation coefficient, PCC)对各气象因素进行相关性分析^[17]。皮尔逊相关系数的值介于[-1, 1]之间,绝对值越大表明该气象变量与输出功率的相关性越高。

1.2 基于 FCM 的相似日聚类

不同天气类型对发电功率的影响极为明显,这将严重影响预测的效果。根据现有研究表明,相似日聚类对于提高光伏发电功率的预测精度有显著效果^[18-19]。因此,进行合理的数据分类对于提高预测精度就显得尤为重要。FCM 是一种基于传统的 K-means 算法改进并结合模糊理论的聚类算法,通过模糊集合的理念对数据进行划分。模糊集合就是算法生成的类,通过计算每个样本点对多个类的隶属度,从而确定每个样本点所属于的类。相较于 K-means 的硬性标准聚类,该方法结合了模糊理论,实现了柔性的模糊划分^[20-21]。聚类中心的计算式和隶属度矩阵的更新如式(1)和(2)所示。

$$v_j^{(t)} = \frac{\sum_{i=1}^n (u_{ij}^{(t-1)})^m x_i}{\sum_{i=1}^n (u_{ij}^{(t-1)})^m} \quad (1)$$

$$u_{ij}^{(t)} = \frac{1}{\sum_{k=1}^c (\frac{d_{ij}^t}{d_{ik}^t})^{\frac{2}{m-1}}} \quad (2)$$

式中:数据集 $X = \{x_1, x_2, \dots, x_n\}$; t 为迭代次数, $v_j^{(t)}$ 为模糊簇聚类中心; c 为聚类中心的个数; n 为样本数据个数; $u_{ij}^{(t)}$ 为第 i 个样本对于第 j 个模糊簇的隶属度,且 $u_{ij}^{(t)} \in [0, 1]$; d_{ij} 为样本 i 到聚类中心 j 的欧式距离; m 为刻画模糊化程度的权重参数,且 $1 < m < \infty$ 。

本文选取总水平辐射变量的平均值、标准差、最大值、变异系数、峰度和偏度作为聚类特征。平均值、标准差和最大值的表达式不再赘述。变异系数 c 、峰度 K_1 和偏度 S 的定义分别如下:

$$c = \frac{\sigma}{\bar{X}} \quad (3)$$

$$K_1 = \frac{\sum_{i=1}^N (x_i - \bar{x})^4}{(N-1)\sigma} \quad (4)$$

$$S = \frac{\sum_{i=1}^N (x_i - \bar{x})^4}{(N-1)(N-2)\sigma} \quad (5)$$

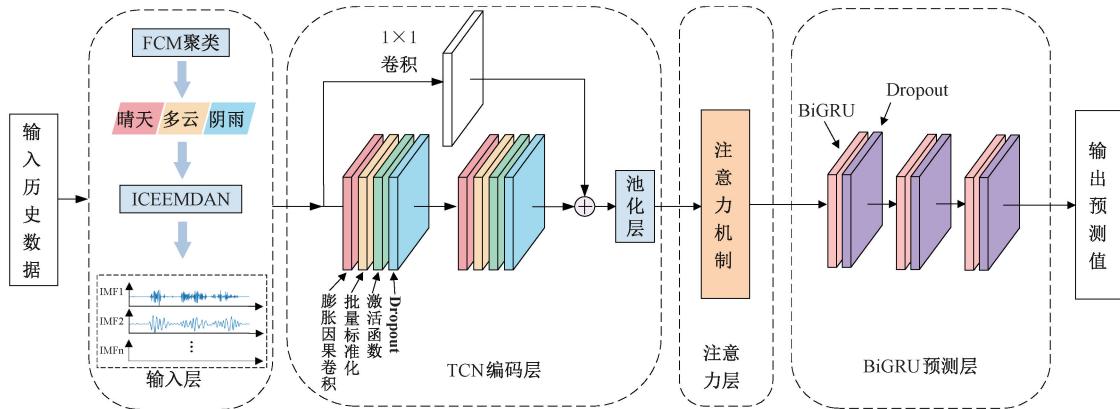


图 1 预测模型结构

2.2 模型相关理论介绍

1) ICEEMDAN

EMD 对于处理非线性及非平稳信号有很强的实用性, 该方法将原始信号分解为一系列能够反映非平稳信号局部特征的模态分量 (intrinsic mode functions, IMF)。ICEEMDAN^[22]是在计算模态分量的过程中加入了均值为 0 且方差为 1 的特殊白噪声, 通过在含高斯白噪声 EMD 分解的第 k 阶 IMF 分量中添加该白噪声, 可以有效的减小模态分量中剩余噪声的影响, 改善在原始信号重构和分解前期模态混叠问题和伪模态分量造成的干扰。ICEEMDAN 的具体分解过程如下:

(1) 定义两个算子分别为 $E_k(\cdot)$ 和 $M(\cdot)$, $E_k(\cdot)$ 为经过 EMD 分解后得到的第 k 阶模态分量, $M(\cdot)$ 为信号的局部均值。设 $x(t)$ 为原始信号; N 为原始信号 $x(t)$ 数据点的总数。

(2) 在原始信号中添加白噪声, 构建信号 $x^i(t) = x(t) + \lambda_0 E_1(\omega^{(i)})$, 其中, λ_0 为噪声标准偏差, $\omega^{(i)}$ 为第 i 次添加的白噪声。

(3) 通过 EMD 计算信号 $x^i(t)$ 的局部均值, 则第一个残差分量 $r_1(t)$ 和第一个模态分量 ($k=1$) $c_1(t)$ 分别为:

$$r_1(t) = \frac{1}{N} \sum_{i=1}^N M(x^i(t)) \quad (6)$$

2 基于 ICEEMDAN 和 TCN-BiGRU 的光伏功率预测研究

2.1 模型构建

本文所提出的预测模型如图 1 所示, 主要包括 4 个部分: 输入层、TCN 编码层、注意力层和 BiGRU 预测层。其中, 输入层用于历史数据的聚类和光伏功率的分解与重构, 以降低数据的复杂度; TCN 编码层用于对光伏序列进行编码并提取相关特征信息; 注意力层的作用是对上一层中所提取到的特征向量分配不同的权重, 以突出关键性特征; BiGRU 预测层对光伏序列进行解码, 进一步挖掘序列的特征信息, 输出预测结果。

$$c_1(t) = x(t) - r_1(t) \quad (7)$$

(4) 计算第 k 个模态 ($k \geq 2$), 即上一次计算得到的残差分量与本次残差分量的差。

$$r_k(t) = \frac{1}{N} \sum_{i=1}^N M(r_{k-1}(t) + \lambda_{k-1} E_k(\omega^{(i)})) \quad (8)$$

$$c_k(t) = r_{k-1}(t) - r_k(t) \quad (9)$$

(5) 重复上述操作步骤直至迭代终止, 获得所有的模态分量和残差。

2) TCN

TCN 是在卷积神经网络 (convolutional neural networks, CNN) 的基础上用于处理时间序列问题的一种深度学习模型。TCN 是将因果卷积和膨胀卷积相结合的时间卷积作为卷积层, 同时与一个 1×1 的卷积融合为一个残差模块, 通过多个残差模块堆叠组合而成。TCN 的网络模型如图 2 所示, 其中图 2(a) 是因果卷积与膨胀卷积的示意图, 图 2(b) 是残差模块的示意图。通过因果卷积, 能保证数据的完整性, 从而更好地处理序列问题; 同时, 膨胀卷积的应用使得 TCN 以较少的层数获得较大的感受野; 残差模块的加入, 可以使历史信息得到很好的保留。因此, 在对时间序列特征进行提取的同时避免了梯度爆炸或梯度消失的问题。此外, 通过 ReLU 激活函数、Dropout 能够有效抑制过拟合现象, 进而提高网络的学习速度和准确

率^[23]。具体来说,假设对于一个输入 $x \in R^n$ 的一维序列和一个卷积核 $f: \{0, \dots, m-1\} \rightarrow R$, 对序列中的元素 s 的膨胀卷积运算如下:

$$F(s) = (x \cdot df)(s) = \sum_{i=0}^{m-1} f(i) \cdot x_{s-d+i} \quad (10)$$

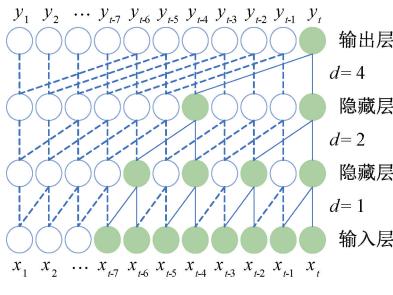
式中: i 为卷积核的位置; m 为卷积核大小; d 为膨胀因子; x_{s-d+i} 表示输入 x 在过去时间步 $s-d+i$ 的值。

因为 TCN 的感受野是由网络的深度 n 、卷积核的大小 k 以及膨胀因子 d 共同决定的,因此在构建深度较大的网络时,可以通过引入残差连接使得 TCN 的感受野能保持稳定。其中,残差模块由网络 $F(x)$ 和输入 x 组成:

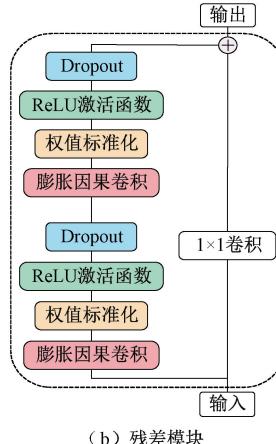
$$o = Activation(x + F(x)) \quad (11)$$

3) 注意力机制

注意力机制(attention mechanisms, AM)的主要作用就从大量信息中筛选出相对更重要的信息,核心是对提取到的特征分配不同的权重,从而筛选出关键特征,突出关键因素的作用^[24]。为了筛选出 TCN 输出特征向量对光伏功率影响较大的特征,本文采用注意力机制编码对特征向量量化权重,如图 3 所示。



(a) 因果卷积与膨胀卷积结构



(b) 残差模块

图 2 TCN 网络模型

经过单层感知器对时域卷积网络所提取到的特征向量 $F_t = [f_{1,t}, f_{2,t}, \dots, f_{n,t}]$ 进行计算可得注意力相关系数 $R_t = [r_{1,t}, r_{2,t}, \dots, r_{n,t}]$:

$$r_{i,t} = \tanh(W_r f_{i,t} + b_r) \quad (12)$$

式中: W_r 为特征注意力权重矩阵; b_r 为偏置向量; \tanh 为

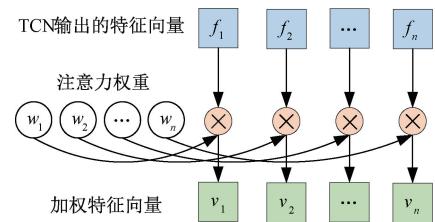


图 3 注意力机制示意图

激活函数,可使权重分配更合理。

通过 Softmax 函数将注意力相关系数 R_t 进行归一化,得到注意力权重 $W_t = [w_{1,t}, w_{2,t}, \dots, w_{n,t}]$:

$$w_{i,t} = \frac{\exp(r_{i,t})}{\sum_{i=1}^n \exp(r_{i,t})} \quad (13)$$

将特征向量 F_t 点乘对应的注意力权重 W_t ,得到加权的特征向量 $V_t = [v_{1,t}, v_{2,t}, \dots, v_{n,t}]$ 。下一步将特征向量 V_t 作为 BiGRU 层的输入进行预测。

$$V_t = [w_{1,t} f_{1,t}, w_{2,t} f_{2,t}, \dots, w_{n,t} f_{n,t}] \quad (14)$$

4) BiGRU

门控循环单元(gated recurrent unit, GRU)是长短期记忆神经网络(long short-term memory, LSTM)的一种变体^[25],将 LSTM 的 3 个门控单元结构简化为重置门和更新门,相比于 LSTM,GRU 的结构更简单,计算速度更快,在保留 LSTM 优点的同时有效提高了样本训练效率。GRU 的结构如图 4 所示,更新门与重置门分别控制上一步隐藏状态的信息在当前隐藏状态中的保留程度与遗忘程度。通过这两个门控机制,GRU 可以有效地选择和更新隐藏状态中的信息,从而实现时序数据的建模。具体公式如下:

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \quad (15)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (16)$$

$$\tilde{h}_t = \tanh(W \cdot [r_t \cdot h_{t-1}, x_t]) \quad (17)$$

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t \quad (18)$$

式中: x_t 为 t 时刻的输入; σ 和 \tanh 为激活函数; z_t 和 r_t 分别为更新门和重置门, h_t 和 \tilde{h}_t 分别为隐藏层和候选隐藏层, W_z , W_r 和 W 分别为更新门、重置门和隐藏层的权重矩阵。

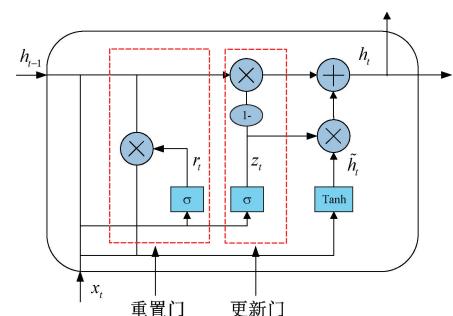


图 4 GRU 结构图

BiGRU^[26]网络模型结合了正向传播和反向传播两个双向 GRU 模型,如图 5 所示,在任一时刻都能接收到同一个输入,克服了单一方向信息流的局限性,其公式如下:

$$\vec{h}_t = \text{GRU}(x_t, \vec{h}_{t-1}) \quad (19)$$

$$\hat{h}_t = \text{GRU}(x_t, \hat{h}_{t-1}) \quad (20)$$

$$h_t = \mathbf{W}_{\vec{h}_t} \vec{h}_t + \mathbf{W}_{\hat{h}_t} \hat{h}_t + b_t \quad (21)$$

式中:GRU()函数表示对输入时间数据的非线性变换; x_t 和 h_t 为 t 时刻隐藏层的输入和输出; \vec{h}_t 与 \hat{h}_t 分别为 t 时刻正向隐藏层的状态输出与反向隐藏层的状态输出; $\mathbf{W}_{\vec{h}_t}$ 与 $\mathbf{W}_{\hat{h}_t}$ 分别表示 t 时刻正向隐藏层状态 \vec{h}_t 与反向隐藏层状态 \hat{h}_t 所对应的权重向量, b_t 表示 t 时刻 BiGRU 隐藏层状态的偏置量。

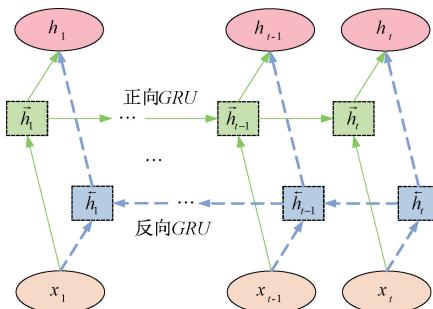


图 5 BiGRU 结构图

3 基于 ICEEMDAN 模态分解的预测模型

3.1 模型整体框架

由于光伏出力的波动性和不确定性,导致其发电功率时间序列存在较强的随机性和较大的噪声。针对这一问题,本文提出一种 ICEEMDAN 及 TCN-AM-BiGRU 的光伏功率预测模型,具体流程如图 6 所示,步骤如下:

1)首先对收集的光伏发电功率数据集进行预处理。对于缺失值,将前后 3 天的同一时间的发电功率取均值进行填补;对于异常值,利用 3σ 原则进行筛选,误差超出区间 $(\mu - 3\sigma, \mu + 3\sigma)$ 的数据视作异常值,将其丢弃的同时以处理缺失值的方法进行填补。

2)对进行预处理后的数据进行相关性分析,利用皮尔逊相关系数选取对光伏输出功率影响较大的气象因素。

3)根据光伏输出功率的幅值大小和波动程度,利用 FCM 聚类将数据集分成晴天、多云和阴雨 3 种相似日。

4)采用 ICEEMDAN 分解算法分别对 3 种相似日对应的历史数据进行自适应分解,得到多个 IMF 分量并计算各个 IMF 分量所对应的排列熵值,根据排列熵值重构高频项、低频项和趋势项,从而降低数据的复杂度。

5)利用本文提出的 TCN-AM-BiGRU 模型进行预测,将 3 部分预测的结果相加集成,得出最终的预测值,实现光伏发电功率的预测。

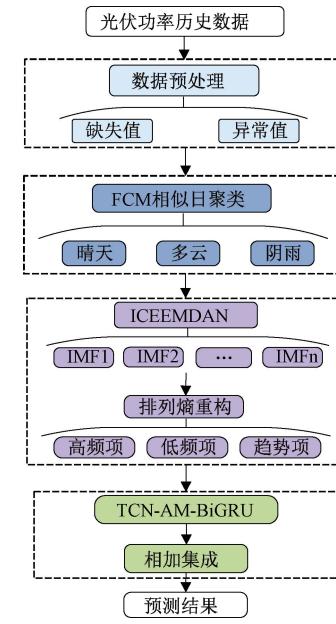


图 6 模型预测流程图

3.2 实验环境

本文实验的硬件环境为 Intel Core i7-12700H CPU@2.30 GHz 处理器,内存 32 GB, GPU 为 NVIDIA GeForce RTX3070。软件平台为 Windows10 操作系统,Python3.6(64 位),TensorFlow-gpu2.6.0 和 Keras2.6.0rc0 深度学习框架,集成开发环境为 PyCharm Community Edition 2022.1.3。

3.3 组合模型参数

为了避免因为特征变量的不同量级影响预测效果,在训练样本数据之前需要进行数据归一化,其公式如下:

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (22)$$

式中: x'_i 为归一化后的数据,且 $x'_i \in [0, 1]$; x_i 为样本数据; x_{\max} 和 x_{\min} 分别为样本数据的最大值与最小值。

在组合模型中,TCN-AM-BiGRU 包括 TCN 特征提取、自注意力机制权重分配和 BiGRU 整合特征,最后通过全连接层输出预测结果。对于 TCN 特征提取模块,由 4 个残差块组成,膨胀因子 d 分别设置为 $[1, 2, 4, 8]$ 。卷积层中使用 Conv1D 函数,卷积核设置为 128,内核大小设置为 5,采用 Relu 激活函数以减少参数之间的依赖关系,从而加快学习速率。对于 BiGRU 模块,设置 2 层双向 GRU,神经元数量为 64。全连接层采用 Relu 激活函数,加入 Dropout 层以抑制迭代过程中的过拟合问题。

3.4 实验评价指标

为了对本文所提出的预测模型的预测效果进行评估,选取平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)和决定系数(coefficient of determination, R^2)作为误差指标,具体公式如下:

$$e_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N |y_i - y'_i|^2 \quad (23)$$

$$e_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - y'_i)^2} \quad (24)$$

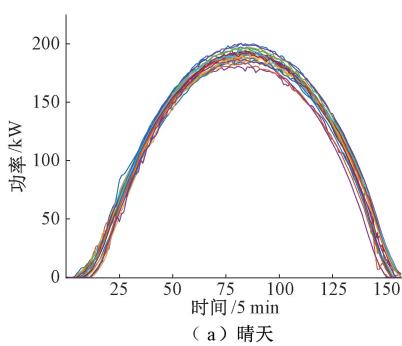
$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - y'_i)^2}{\sum_{i=1}^N (y_i - \frac{1}{n} \sum_{i=1}^N y_i)^2} \quad (25)$$

式中: N 为测试样本数目, y_i 为光伏发电功率的实际值, y'_i 为预测模型输出的值。

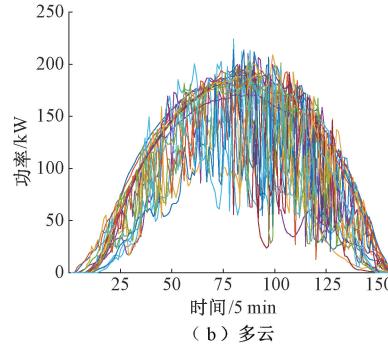
4 算例及实验结果分析

4.1 相关性分析与相似日聚类

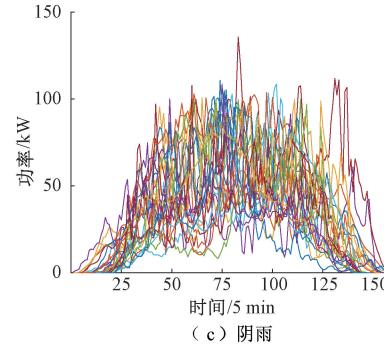
本文使用的实验数据是某光伏电站 2022 年 6~8 月的光伏发电功率和其相对应的气象数据,采样间隔为 5 min。利用皮尔逊相关系数进行相关性分析,结果如表 1 所示。根据表 1 中相关系数 R 可知,辐照度是影响光伏发电功率的关键因素。总水平辐射和总倾斜辐射的相关系数都达到了 0.9 以上,漫射水平辐射和漫射倾斜辐射也达到了 0.5;其次环境温度、相对湿度、风速和风向对发电功率存在一定程度的影响,其中风向和湿度存在负相关性。由于采集的该地区数据中降雨量较少,对光伏发电功率几乎无影响。综合分析,本文选取总水平辐射、漫射水平辐射、总



(a) 晴天



(b) 多云



(c) 阴雨

图 7 FCM 算法聚类结果

4.2 数据分解与重构

在对实验数据进行相似日聚类之后,将每种天气的最后一天作为测试集,其余数据作为训练集。利用 ICEEMDAN 分别对 3 种天气类型数据进行自适应分解。以晴天为例,分解得到 11 组本征模态分量和趋势项,如图 8 所示。由图可知,各 IMF 分量的频率稳定,没有出现模态混叠现象,IMF1 的频率最高,IMF11 的频率最低,分量的频率逐步减小,数据也趋于稳定。

为了降低预测模型的复杂度,提高预测精度,本文通过计算排列熵值(permuation entropy, PE)对模态分量进行高低频重构。排列熵值能体现出时间序列的复杂程度和波动性:熵值越大,则序列越复杂、波动性越强,反之则越平稳。分别计算各 IMF 分量的排列熵值,如表 2 所示。

倾斜辐射、漫射倾斜辐射、环境温度和相对湿度作为影响光伏发电功率的主要气象因素。

表 1 光伏发电功率与环境因素的相关系数

环境因素	相关系数 R
总水平辐射	0.96
漫射水平辐射	0.55
总倾斜辐射	0.94
漫射倾斜辐射	0.58
温度	0.36
相对湿度	-0.29
降雨量	-0.02
风速	0.06
风向	-0.03

出于对光伏发电特性的考虑,截取每天 6:00~19:00 时段的光伏发电功率进行聚类绘图。图 7 所示的是 FCM 聚类后的结果,共分为晴天、多云和阴雨 3 种相似日类型。根据聚类结果可知,晴天的光伏发电功率整体上看较为平缓稳定,偶尔发生细微波动;多云时的功率曲线相比晴天有着频繁的波动,当太阳被云层遮挡时的功率波动幅度较大;雨天的发电功率相对来说较低,且波动剧烈极不稳定。

IMF1~4 熵值大于 0.6,重构为高频项;IMF5~11 熵值小于 0.6,重构为低频项;最后一个为趋势项,重构后的序列如图 9 所示。重构之后的分量变化较为规律,利于进一步挖掘各序列的潜在波动特征。

4.3 实验结果分析

为了验证本文所提出的组合预测模型的有效性和优越性,搭建了多个模型分别对晴天、多云和阴雨 3 种天气类型进行预测,包括:GRU (M1)、BiGRU (M2)、TCN-BiGRU (M3)、TCN-AM-BiGRU (M4)、CEEMDAN-TCN-AM-BiGRU (M5)、本文模型但未进行相似日聚类 (M6) 和 ICEEMDAN-TCN-AM-BiGRU (本文模型, M7)。对于 M6,训练集为待测日之前的所有数据。其他对比模型的均采用相同的训练集和训练集,且所提模型的相同模块均设

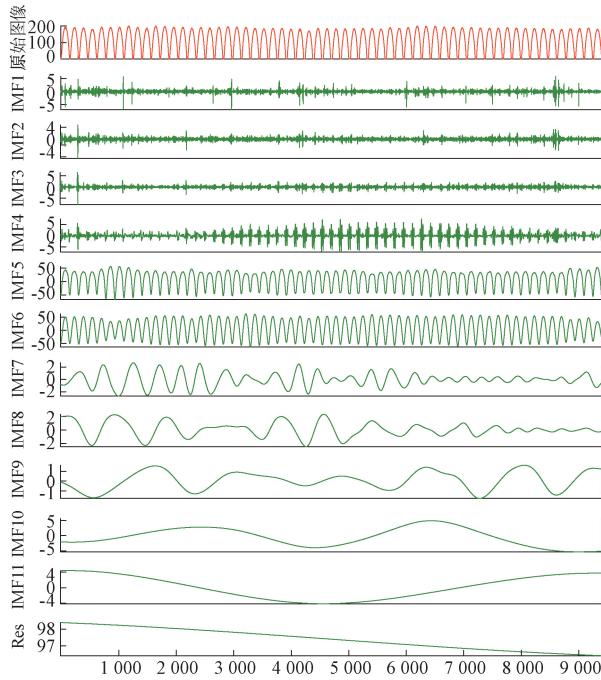


图 8 晴天的 ICEEMDAN 分解结果

表 2 各本征模态分量对应的排列熵值

IMF1	IMF2	IMF3	IMF4	IMF5	IMF6
0.993 1	0.893 1	0.739 2	0.605 7	0.435 5	0.430 2
IMF7	IMF8	IMF9	IMF10	IMF11	Res
0.410 7	0.404 2	0.396 2	0.384 1	0.337 3	—

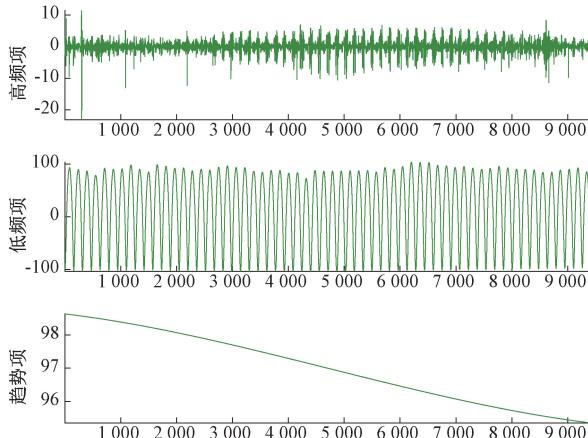


图 9 分量重构结果

置相同的参数,具体的参数如表 3 所示。

为了保证对所提预测模型精度评估的客观性,对各天气类型都进行 10 次重复实验,将 10 次实验的结果取平均值作为最终的预测值。图 10 为不同天气类型的预测结果,表 4 展示的是对于不同天气类型下各预测模型的预测效果。相比于其他模型,本文所提出的预测模型 M7 的预测结果更接近真实值,预测效果是最佳的。同时,注意到

表 3 模型相关参数设置

模型参数	数值
GRU 层数	2
GRU 单元数	32 和 32
TCN 残差块数	4
卷积层函数	Conv1D
卷积核数量	128
卷积核大小	5
扩张因子	[1,2,4,8]
Dropout 灭活率	0.2
注意力机制单元数	20
BiGRU 层数	2
BiGRU 单元数量	64 和 64
激活函数	ReLU
优化器	Adam
学习率	0.01
批量处理大小	512
训练次数	100

同样采用本文方法但未进行相似日聚类模型 M6 预测效果不佳,可见对数据进行有效分类,构造合理可信的训练集和测试集,可以有效地提高模型的预测精度。

结合图 10 和表 4,相比于晴天,在多云和阴雨的情况下,所有模型的准确度都较低。这主要是由于多云和阴雨的天气因素相对更混乱复杂,从而影响了预测的效果。总的来说,本文所提模型的预测性能优于一些传统方法,在预测效果上有显著改善。以下分别对 3 种类型的相似日进行具体分析。

相似日类型为晴天时,各模型的功率预测曲线与实际功率曲线都比较吻合,其拟合度均达到了 0.95 以上。可见,对于波动频率较小的序列,每个模型都有着较好的预测效果,可以准确识别出这种相似日下的波动特征。其中,模型 M7 的预测模型最为准确,拟合度达到了 0.996 5,且其误差最小, e_{MAE} 与 e_{RMSE} 分别为 2.840 6 kW 和 3.598 0 kW。通过对比模型 M3 和 M4, e_{MAE} 与 e_{RMSE} 分别提升了 22.24% 和 25.58%,表明通过增加注意力机制可以更加凸显光伏功率的特征,合理地分配特征权重,从而提高了模型的预测精度。对比单一模型 M1 和 M2, M2 的预测效果要优于 M1,验证了双向 GRU 相比于单向 GRU 更能抓住光伏功率的时间相关性,提高预测的准确度。

相似日类型为多云时,由于多云的天气因素相对于晴天而言较为复杂且多变,因此多云天气下的预测效果略差。本文所提出的预测模型的拟合度为 0.975 4, e_{MAE} 与 e_{RMSE} 分别为 7.559 3 kW 和 9.403 2 kW。相比于采用 CEEMDAN 分解模型的 M5,拟合度 R^2 提高了 0.52%, e_{MAE} 与 e_{RMSE} 分别提高了 8.73% 和 10.21%。未采用分解算法的模型 M1~4 的预测效果相对较差,是因为数据集在

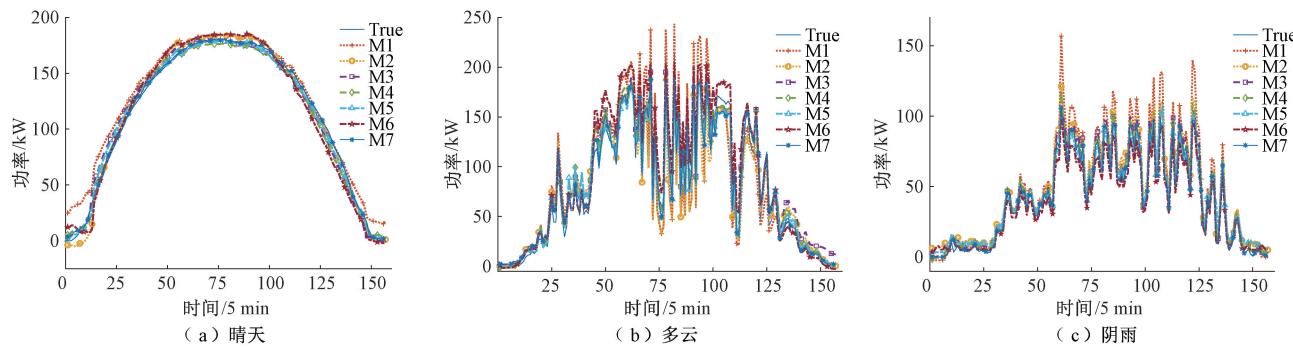


图 10 不同天气类型的预测结果

表 4 不同预测模型的误差对比

晴天	MAE	RMSE	R ²	多云	MAE	RMSE	R ²	阴雨	MAE	RMSE	R ²
M1	10.599 5	12.081 4	0.961 2	M1	14.782 6	18.358 0	0.903 8	M1	8.457 9	10.654 8	0.889 4
M2	7.821 5	9.514 2	0.972 9	M2	13.874 6	15.772 6	0.926 1	M2	7.210 2	9.017 4	0.913 2
M3	6.349 4	8.548 5	0.980 3	M3	11.873 1	13.987 2	0.948 9	M3	6.351 6	8.283 7	0.938 6
M4	4.936 7	6.361 1	0.989 1	M4	10.913 4	13.395 9	0.953 8	M4	5.829 4	7.795 2	0.949 7
M5	3.895 5	4.909 5	0.993 0	M5	8.282 4	10.472 5	0.970 3	M5	4.581 7	6.366 3	0.964 6
M6	6.603 6	8.673 2	0.982 7	M6	12.072 4	13.885 3	0.946 7	M6	6.861 4	8.878 1	0.920 8
M7	2.840 6	3.598 0	0.996 5	M7	7.559 3	9.403 2	0.975 4	M7	3.867 5	5.386 4	0.970 3

未进行分解和去噪的情况下其质量较差,在预测过程忽略了一些有效信息,导致精度变差。总体来说,在天气因素多变的情况下,本文模型也能灵敏地察觉变化趋势并且做出较高精度的响应。

相似日类型为雨天时,辐照度较弱和天气因素随机性较强,因此从整体上上看,光伏功率的幅值明显较低且波动也更加频繁。各模型的预测功率曲线与实际功率曲线之间均存在一定的偏差,尤其是在采样点 35~125 之间频繁波动。本文所提模型是最接近实际功率曲线的,其拟合度相比于模型 M1~4 在拟合度上分别提高了 9.10%、6.25%、3.38% 和 2.17%。预测精度仅次于本文模型的是 M5,这是因为 ICEEMDAN 相比于 CEEMDAN 加入了改进的自适应白噪声,在信号处理中去噪的效果更为出色,因此可以有效地处理光伏发电功率序列中存在的噪声干扰,因此预测效果本文略高于模型 M5。

5 结论

本文综合考虑了影响光伏发电功率的气象因素,提出了一种基于 ICEEMDAN 和 TCN-AM-BiGRU 的光伏功率预测模型。主要结论如下:FCM 算法能有效对光伏功率数据进行相似日聚类,划分为晴天、多云和阴雨 3 种类型,通过对相似日进行深度学习有助于进一步地特征挖掘。将 ICEEMDAN 和 FE 相结合,对光伏功率数据的分解与重构,一方面降低了历史数据中的噪声干扰,另一方面降低了数据的复杂性和波动性,减小了数据波动和非平稳序列的影响,有助于对光伏功率特征的提取,能够实现较好的

预测效果。融合 TCN 和 BiGRU 两个网络模型,充分利用 TCN 在处理时间序列问题的优势以及 BiGRU 在捕捉序列数据的双向依赖关系的优势,同时引入注意力机制,为 TCN 提取的特征赋予权重,能更好地提取光伏功率序列的特征。实验表明,对比其他模型,本文所提模型的能够达到较高的预测精度。

参考文献

- 王开艳,杜浩东,贾嵘,等. 基于相似日聚类和 QR-CNN-BiLSTM 模型的光伏功率短期区间概率预测[J]. 高电压技术,2022,48(11):4372-4388.
- 王蓓蓓,亢丽君,苗曦云,等. 考虑可信度的新能源及需求响应参与英美容量市场分析及思考[J]. 电网技术,2022,46(4):1233-1247.
- WANG L, MAO M, XIE J, et al. Accurate solar PV power prediction interval method based on frequency-domain decomposition and LSTM model[J]. Energy, 2023, 262:125592.
- 俞敏,王晓霞. CS 算法优化 VMD-BiLSTM-AM 的光伏功率预测[J]. 计算机系统应用,2023, 32 (2): 347-355.
- 袁建华,蒋文军,李洪强,等. 基于 SSA-BiLSTM 非线性组合方法的光伏功率预测[J]. 电子测量技术,2023, 46(21):63-71.
- WANG M, PENG J, LUO Y, et al. Comparison of different simplistic prediction models for forecasting PV power output: assessment with experimental

- measurements[J]. Energy, 2021, 224:120162.
- [7] HUMADA A M, DARWEESH S Y, MOHAMMED K G, et al. Modeling of PV system and parameter extraction based on experimental data: Review and investigation[J]. Solar Energy, 2020, 199:742-760.
- [8] MAYER M J, GRÓF G. Extensive comparison of physical models for photovoltaic power forecasting[J]. Applied Energy, 2021, 283:116239.
- [9] 冯沛儒,江桂芬,徐加银,等.基于 CEEMD-BiLSTM-RFR 的短期光伏功率预测[J].科学技术与工程,2024,24(5):1955-1962.
- [10] 赵滨滨,王莹,王彬,等.基于 ARIMA 时间序列的分布式光伏系统输出功率预测方法研究[J].可再生能源,2019,37(6):820-823.
- [11] 于红伟,许国泽,何旭东,等.基于相似样本和多模型动态最优组合的光伏功率预测[J].电网与清洁能源,2021,37(9):92-99.
- [12] 赖昌伟,黎静华,陈博,等.光伏发电出力预测技术研究综述[J].电工技术学报,2019,34(6):1201-1217.
- [13] WANG S, SUN Y, ZHOU Y, et al. A new hybrid short-term interval forecasting of PV output power based on EEMD-SE-RVM[J]. Energies, 2019, 13(1): 87.
- [14] 朱正林,张冕.基于 AO 优化 VMD-CE-BiGRU 的光伏发电功率预测[J].国外电子测量技术,2022,41(10):56-61.
- [15] LI P, ZHOU K, LU X, et al. A hybrid deep learning model for short-term PV power forecasting [J]. Applied Energy, 2020, 259:114216.
- [16] LI T, QIAN Z, HE T. Short-term load forecasting with improved CEEMDAN and GWO-based multiple kernel ELM[J]. Complexity, 2020, 2020:1209547.
- [17] 韩莹,朱宏宇,李琨.融合聚类及随机配置网络的短期光伏功率预测[J].电子测量与仪器学报,2023,37(11):205-216.
- [18] 吕伟杰,方一帆,程泽.基于模糊 C 均值聚类和样本加权卷积神经网络的日前光伏出力预测研究[J].电网技术,2022,46(1):231-238.
- [19] 孟安波,陈嘉铭,黎湛联,等.基于相似日理论和 CSO-WGPR 的短期光伏发电功率预测[J].高电压技术,2021,47(4):1176-1184.
- [20] 毕锐,丁明,徐志成,等.基于模糊 C 均值聚类的光伏阵列故障诊断方法[J].太阳能学报,2016,37(3):730-736.
- [21] 龙小慧,秦际赟,张青雷,等.基于相似日聚类及模态分解的短期光伏发电功率组合预测研究[J/OL].电网技术,1-12 [2024-03-18]. <https://kns.cnki.net/kcms/detail/11.2410.TM.20240223.1537.004.htm>.
- [22] 俞斌,孟伟,俞天杨,等.基于 ICEEMDAN-CNN-K-shape 的智慧园区短期负荷预测研究[J].国外电子测量技术,2023,42(5):103-112.
- [23] 孙隽丰,李成海,曹波.基于 TCN-BiLSTM 的网络安全态势预测[J].系统工程与电子技术,2023,45(11):3671-3679.
- [24] 马佳成,王晓霞,杨迪.基于 Attention 机制的 TCN-LSTM 非侵入式负荷分解[J].电力信息与通信技术,2023,21(8):43-51.
- [25] 赵杰,解则晓,刘世萱.基于能量熵 VMD 最优分解与 GRU 循环神经网络的潮汐预测精度提升方法研究[J].仪器仪表学报,2023,44(12):79-87.
- [26] 张朝龙,罗来劲,刘惠汉,等.基于增量能量法和 BiGRU-Dropout 的锂电池健康状态估计[J].电子测量与仪器学报,2023,37(1):167-176.

作者简介

白隆,硕士研究生,主要研究方向为新能源微电网与智能微电网技术。

E-mail:long18352622013@163.com

俞斌(通信作者),硕士,副教授,主要研究方向为新能源发电与并网技术、先进储能技术、电力电子应用技术。

E-mail:2450276860@qq.com