

DOI: 10.19783/j.cnki.pspc.201494

基于时间序列的深度学习光伏发电模型研究

刘倩, 胡强, 杨凌帆, 周杭霞

(中国计量大学, 浙江 杭州 310018)

摘要: 为了减少光伏系统接入电网产生的不利影响, 并对预测光伏功率输出进行研究, 提出了一种基于数据中潜在季节类别的混合深度学习模型。整个模型分为三个阶段, 即聚类、训练和预测。在聚类阶段, 采用相关分析和自组织映射来选择历史数据中相关性最高的因素。在训练阶段, 将卷积神经网络、长短期记忆神经网络和注意力机制相结合, 以构建用于预测的混合深度学习模型。在预测阶段, 按测试集的月份选择分类的预测模型。实验结果表明, 该实验方法在 7.5 min 内的间隔预测中具有较高的准确性。

关键词: 光伏发电; 光伏功率预测; 季节类别; 自组织映射; 深度学习; 注意力机制

Deep learning photovoltaic power generation model based on time series

LIU Qian, HU Qiang, YANG Lingfan, ZHOU Hangxia

(China Jiliang University, Hangzhou 310018, China)

Abstract: In order to stabilize the process which integrates photovoltaic (PV) power into a power grid, a hybrid deep learning model based on potential season category in the data is proposed after researching the prediction of PV output power. The overall model is divided into three stages, namely, clustering, training and prediction. In the clustering stage, correlation analysis and self-organizing mapping are employed to select the features with the highest correlation in historical data. In the training stage, the CNN, LSTM and the attention mechanism are combined to construct a hybrid deep learning forecasting model. In the prediction stage, a particular classification model is selected based on the month of the testing dataset. The experimental result shows that this proposed model has significantly improved prediction accuracy in terms of a time interval of 7.5 min.

This work is supported by the Basic Public Welfare Research Project of Zhejiang Province (No. LGF18F020017).

Key words: PV power generation; PV power prediction; season category; self-organizing mapping; deep learning; attention mechanism

0 引言

光伏发电作为可持续能源, 具有低碳消耗, 适应各种应用以及安装和维护成本低的优点^[1-4]。由于受天气条件的影响, 光伏电能接入并网系统后, 会对整个电网系统的稳定性产生很大程度的影响。随着光伏发电的广泛使用, 光伏电能接入电网给电网系统的安全性带来了巨大的挑战^[5-10]。

近年来, 随着自然语言处理、图像处理、时间序列分析的快速发展, 机器学习和深度学习技

术已应用到各个领域^[11-15]。文献[16]考虑光伏发电的随机性和不稳定性, 提出用加权的马尔科夫链修正 SVM 预测模型, 以提高预测精度。文献[17]为了提高光伏功率日前短期预测的准确率, 基于日前数值天气预报, 建立考虑了季节循环和日循环的统计预测模型, 然后分不同时刻应用 3 种算法(分类中位数、分类回归和分类聚类)对原始短期预测值进行修正, 并应用最小方差组合算法对这 3 种单体算法进行组合。文献[18]提出了一个模拟全球每小时太阳辐照度的预测模型, 该系统模型分为了两个阶段: 第一阶段为聚类阶段, 通过 K 均值聚类算法(K-Means Clustering Algorithm)将原始数据分为多组, 每个组代表不同天气类型

基金项目: 浙江省基础公益研究计划项目资助(LGF18F020017)

的数据；第二阶段，采用决策树、人工神经网络和支持向量机(Support Vector Machine, SVM)进行预测，该方法通过聚类算法将数据分为多组，训练多个预测模型，降低了整体数据中异常数据产生误差的可能性，但在第二阶段只采用了经典算法进行预测，预测算法没有创新。文献[19]提出了一种基于天气类型的混合深度学习的方法，采用 1 h 为时间步长进行光伏功率输出预测，所提出的深度学习的方法采用了三个步骤：分类、训练和预测，分类步骤是由自组织映射 (Self-Organizing Map, SOM) 算法^[20]和学习矢量量化 (Learning Vector Quantization, LVQ) 算法^[21]网络组成，用于对收集的光伏历史数据进行分类，训练阶段使用 SVM 算法进行模型训练，预测阶段采用模糊推理方法选择合适的训练模型进行预测，该算法结构分为分类、训练和预测三个阶段，结构清晰。但是 LVQ 算法与 SOM 算法同为聚类算法重复使用，造成算法结构复杂化。文献[22]提出了一种可选择的多模型光伏发电间隔预测方法，该方法结合了文献[23]提出的双通道网络模型预测方法，将归一化后的数据放入两个并行的卷积神经网络(Convolutional Neural Network, CNN)中进行特征提取，经融合层送入 LSTM 进行光伏功率预测，该方法训练多个 CNN 算法和 LSTM 算法组合的预测模型来提高模型的预测精度，但是两组归一化的数据没有分类，实验数据中的异常数据可能会影响预测精度。文献[24]提出了一种融合注意力机制(Attention)和卷积门限循环神经网络的读者情绪预测方法，利用注意力机制自适应感知上下文信息来提取影响读者情绪的文本特征。目前注意力机制算法在图像和文本中的应用较为广泛，较少应用于光伏预测中。

本文提出了一种结合聚类算法和深度学习技术的光伏发电预测模型结构。整个模型可以分为三个阶段。第一阶段，使用 SOM 算法将训练数据分为四个类别，并分别模拟了四个季节。第二阶段，使用注意力机制、CNN 和 LSTM 构建模型，使用 CNN 可以更好地获得数据中潜在的特征信息。第三阶段是预测阶段，根据测试数据集的月份，采用最合适的预测模型来预测测试数据集的光伏功率。实验结果表明，该方法在短时间间隔的光伏预测中具有较高的准确性。

1 构建模型方法

本研究的数据集选用我国南部一座光伏电站的 2014 年 10 月至 2018 年 9 月内间隔为 7.5 min

的实时数据。在研究过程中将 2014 年至 2016 年的数据作为训练数据集，将 2017 年至 2018 年的数据作为测试数据集。光伏电站每隔 7.5 min 使用远程传感器记录一次光伏数据。由于电站使用三相逆变器设备，因此采集数据包含光伏组件温度、三个交流电流(交流电流 1、交流电流 2 及交流电流 3)、三个交流电压(交流电压 1、交流电压 2 及交流电压 3)、两个直流电流(直流电流 1 和直流电流 2)、两个直流电压(直流电压 1 和直流电压 2)、频率、相位和光伏输出功率等信息。因频率和相位不会随光伏输出功率而变化，所以在实验中并未使用频率和相位数据信息。

首先计算数据中的功率数据与其他因素数据之间的相关系数，因为光伏电站的发电功率不稳定性是外界因素共同作用的结果^[25]，所以针对多因素组合对光伏功率的影响进行了相关性分析，结果如表 1 所示，这里引入了计算修正 RV 系数的组合相关性检验法^[26]。修正 RV 系数(RV_{mod})是一种基于矩阵计算的相关性分析方法。修正 RV 系数的计算过程为

$$RV_{\text{mod}} = \frac{\text{tr}(\mathbf{JK})}{\sqrt{\text{tr}(\mathbf{J})^2 \text{tr}(\mathbf{K})^2}} \quad (1)$$

式中： $\mathbf{J} = \mathbf{M} \cdot \mathbf{M}^T - \text{diag}(\mathbf{M} \cdot \mathbf{M}^T)$ ， \mathbf{M} 代表影响因素矩阵，包括交流电流 2(AC2)和交流电流 3(AC3)； $\mathbf{K} = \mathbf{N} \cdot \mathbf{N}^T - \text{diag}(\mathbf{N} \cdot \mathbf{N}^T)$ ， \mathbf{N} 代表光伏发电输出矩阵， $\text{diag}()$ 为矩阵对角线元素提取函数； $\text{tr}()$ 为矩阵对角线元素求和函数； RV_{mod} 取值为(-1, 1)，当 RV_{mod} 接近 -1 或 1 时，因素与输出功率之间的相关性更高。

表 1 光伏数据因素的相关系数

Table 1 Correlation coefficient of PV data factors

光伏数据因素名称	相关系数
直流电压 1/V	0.19
直流电压 2/V	0.20
直流电流 1/A	0.13
直流电流 2/A	0.13
交流电压 1/V	0.10
交流电压 2/V	0.11
交流电压 3/V	0.14
交流电流 1/A	0.28
交流电流 2/A	0.998
交流电流 3/A	0.992
交流电流 2 A 和交流电流 3 A 组合	0.73
光伏组件温度/°C	0.16

通过表 1 可以看出, 因素 AC2 和 AC3 对光伏发电功率影响最大, 两者的系数也非常接近, 因此本研究进行实验比较了 AC2 和 AC3 数据集的实验结果。尽管系数差异不大, 但 AC2 的预测精度明显高于 AC3。因此本研究单独提取了 AC2 数据作为光伏发电功率的主要影响因素。

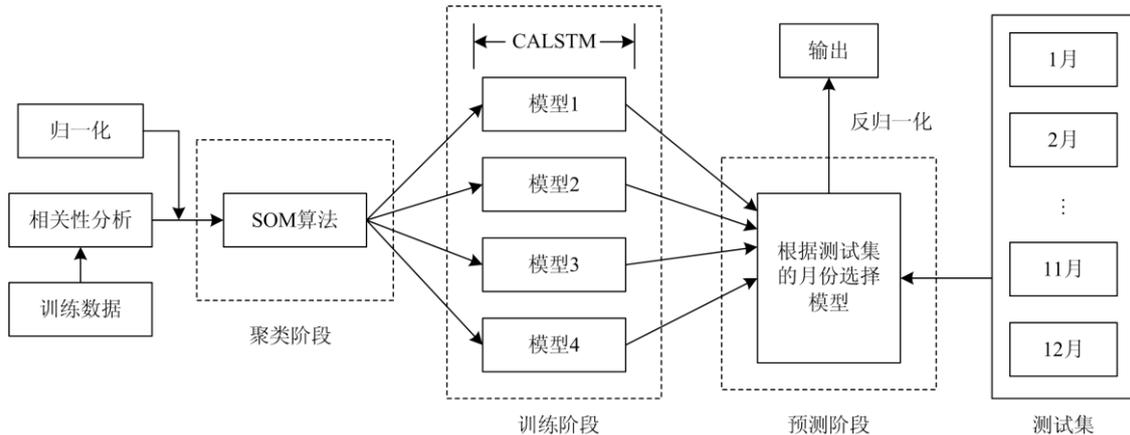


图 1 本文提出的混合模型的结构

Fig. 1 Structure of the proposed hybrid model

1.1.1 模拟四个季节的原因

首先尝试按季节对数据进行分类, 分类方式为: 将相同季节的数据进行合并, 并使用 CNN-ALSTM 对这四组数据进行了训练, 训练结果显示其中某个月的预测结果很差。进一步尝试按月对数据进行分类来训练预测模型, 将两年的数据根据月份合并为 12 个数据集, 对每个数据集进行训练, 并使用相同月份的测试集进行预测, 并没有得到令人满意的预测结果。结合以上尝试结果, 本实验选择聚类算法找出数据中潜在的季节性信息, 来提高预测精度。

1.1.2 聚类算法的选择

实验数据中不包含天气类别的数据, 为了找出数据中潜在类别信息, 需要一种具有自动聚类功能的算法来对数据进行分析。常见的聚类算法包括 K 均值、均值漂移聚类、基于密度的聚类 (DBSCAN) 和模糊聚类 (FCM), 其中均值漂移聚类和 DBSCAN 无法指定输出类别的数量和输出层的规范。由于通过聚类算法分类的四个类别没有标签, 因此在比较准确性的过程中, 先将原始数据 (24 个月中每天的光伏实验数据) 按照正常的季节分别标记为春季、夏季、秋季、冬季; 如果季节标签在分类结果中一个类别中最多, 则假定该类别为这个季节; 然后查看这个类别中其他月份是否为这个季节的月份, 如果不是, 则判断为分

1.1 模型概述

本文提出的混合深度学习模型结构如图 1 所示。SOM 算法将输入的训练数据分为四个类别, 每个类别都使用 CNN、LSTM 和注意力机制算法进行训练。训练完成后, 根据测试集的月份选择合适的预测模型测试集进行预测。

类错误。在一个百分比的范围内使用该方法分析图 2 中三种聚类算法的正确率, 实验结果表明, SOM 算法的正确率最高。

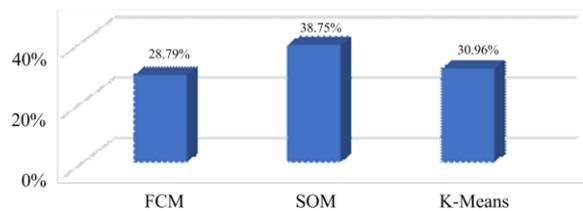


图 2 聚类算法的正确率

Fig. 2 Accuracy of clustering algorithms

1.1.3 SOM 竞争层的设置

SOM 竞争层的设置如图 3 所示。X 轴表示竞争层的大小, Y 轴表示竞争层中输出神经元的数量。结果表明, 最适合 SOM 的竞争层大小是 2×2 。

1.2 聚类阶段

聚类阶段采用的是 2014 年至 2016 年 AC2 的实验数据。考虑到每月的天数不同且可能会出现因天气或者设备缺失数据的情况, 故从每月中选择 15 天的完整数据作为新的数据集, 其中每天的数据量包含 192 个 AC2 实时数据。由于在聚类实验中存在具有相同月份标签的数据集被分为不同类别的情况, 为避免在预测阶段引起混乱, 首先将 24 个数据集中具有相同月份标签的数据进行

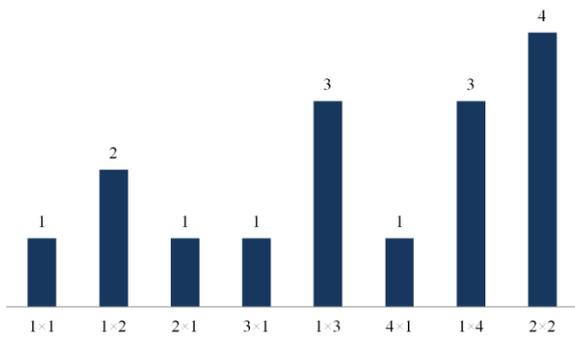


图3 SOM竞争层的设置

Fig. 3 Settings of SOM competition layer

合并,得到12个具有月份标签和相同数据量的数据集,接下来使用SOM算法对12个月的数据集进行聚类计算,找出数据中潜在的季节性信息。

SOM模型结构如图4所示。SOM算法的学习步骤如下所述。

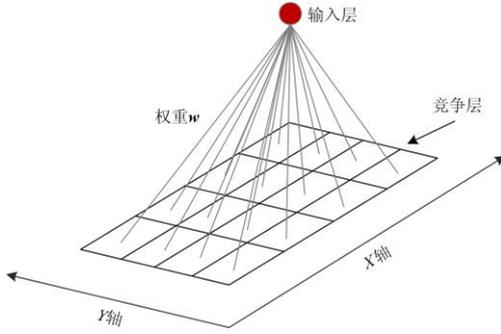


图4 SOM算法的模型结构

Fig. 4 Structure of SOM

(1) 初始化竞争层中各神经元对应的权重向量。

(2) 选择 \mathbf{X}_c (输入向量) 和 \mathbf{w}_j (连接权重向量) 之间的欧式距离最小的神经元节点 d , 即 $\min\{d_{jc}\}$ 。接下来通过式(3)更新获胜神经元节点 d 以及其领域内其他节点的权值 W_{ij} 。

(3) 整个算法返回(2), 令 $t=t+1$, 重新输入输入层, 直到最大迭代次数或学习速率收敛, 循环结束。

其中: $\eta(t)$ 为(0,1)的第 t 步的学习速率; $W_{ij}(t)$ 为神经元节点 i 与 j 的权值; X_i 为神经元节点 i 的输入值; $h_{d,j}(t)$ 为邻域函数。 $h_{d,j}(t)$ 通常使用高斯函数, 如式(4)所示。神经元节点 d 与 j 之间的距离为 d_{dj}^2 ; $r(t)$ 为邻域半径; $\text{int}()$ 为取整函数; T 为学习频率。调整规则如式(5)和式(6)所示。

$$\|\mathbf{X}_c - \mathbf{w}_j\| = \min\{d_{jc}\} \quad (2)$$

$$W_{ij}(t+1) = W_{ij}(t) + \eta(t)h_{d,j}(t)(X_i - W_{ij}(t)) \quad (3)$$

$$h_{d,j}(t) = \exp\left(-\frac{d_{dj}^2}{2r^2(t)}\right) \quad (4)$$

$$r(t+1) = \text{int}\left((r(t)-1) \times \left(1 - \frac{t}{T}\right)\right) + 1 \quad (5)$$

$$\eta(t+1) = \eta(t) - \frac{\eta(0)}{T} \quad (6)$$

实验中将12个数据集放入SOM的输入层, 在竞争层中, SOM不断更新数据集权重以使数据集相互竞争。最后将12个数据集分为四组: 1、4、10月, 2、11、12月, 3、6、7月和5、8、9月, 分类结果与四季的分类结果相比偏差大的原因是光伏功率输出主要与光照强度、环境温度和环境湿度、风速有关, 这些因素直接影响光伏组件, 从而使功率输出产生变化。分类出来的每组数据由于综合的环境因素最为接近, 导致功率输出的变化最相近, 所以与四季分类的结果相比, 一些月份与别的季节月份聚类成一个训练集。

1.3 训练阶段

在训练阶段将上述聚类阶段分类好的4个训练数据集放入训练模型中, 训练结束后, 得到4个预测模型。训练过程遵循时间序列的训练方法, 将4组训练数据分别定义为 $[y_1, y_2, y_3, \dots, y_n]$, 其中 y 代表AC2数据, n 代表每个类别中包含的AC2数据的数量。在实验中, 设置时间步长 i , $[y_1, y_2, \dots, y_i]$ 设置为新的训练集, 并将 y_{i+1} 作为目标值, 然后将新的训练集放入训练模型中, 在训练过程中调整模型参数, 以便预测输出值接近。接着, 将 $[y_2, y_3, \dots, y_{i+1}]$ 放入训练模型并调整模型参数, 以使得到的预测值不断接近, 依此类推, 直到目标值为 y_n , 结束模型训练。最后得到4个训练后的预测模型。该实验的训练模型结构由两个CNN卷积核层, 具有注意力机制的LSTM层和完全连接层(FC)组成。训练模型的结构如图5所示。

图5中, CNN层的功能是提取输入数据的特征, 实现从时间序列到高级特征的信息抽象, 并获得更多潜在的数据信息, 从而提高预测精度。

在CNN层中获得的特征向量会被输入到LSTM层中进行训练, 得到LSTM隐层输出向量。通过注意力机制方法, 可以将更高的权重分配给更接近目标值的LSTM输出向量, 得到下一时刻光伏功率的预测值, 从而提高了模型的预测能力。

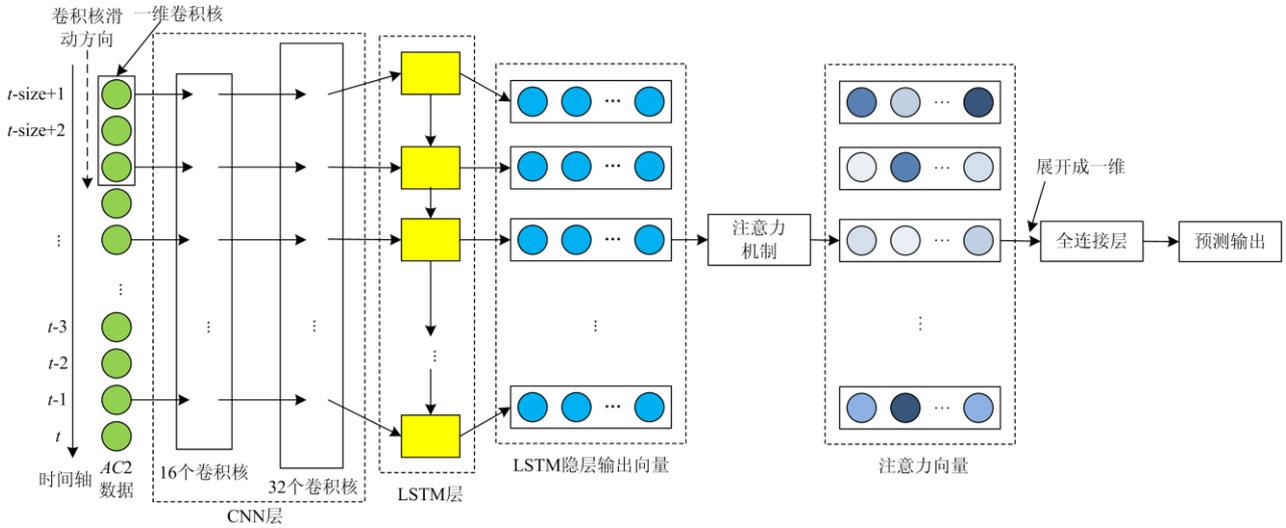


图 5 训练模型结构

Fig. 5 Structure of training model

1.3.1 LSTM 算法

国内外许多研究者已经将 CNN 和 LSTM 结合起来用于预测实验研究^[23,26-27]。本文采用 CNN-LSTM 结合网络进行模型训练和预测。LSTM 模型的流程中包含四个重要元素：单元状态、输入门、遗忘门和输出门。其中输入门、遗忘门和输出门用于控制单元状态中所包含信息的更新、维护和删除。LSTM 的计算过程可以表示为

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (7)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (8)$$

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (9)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (10)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (11)$$

$$h_t = O_t \cdot \tanh(C_t) \quad (12)$$

式中： W_f 、 W_i 和 W_o 分别是遗忘门、输入门、输出门的权值矩阵； b_f 、 b_i 和 b_o 分别是遗忘门、输入门、输出门的偏置项； σ 是 sigmoid 激活函数； \tanh 是双曲正切激活函数。

1.3.2 注意力机制

本文提出的模型使用 LSTM 隐层输出向量 $H = \{h_1, h_2, \dots, h_t\}$ 作为注意力机制的输入，该注意力机制将找到 h_t 的关注权重 α_t ，其计算公式为

$$e_i = \tanh(W_h h_i + b_h) \quad (13)$$

$$\alpha_i = \frac{\exp(e_i)}{\sum_{i=1}^t \exp(e_i)} \quad (14)$$

式中： W_h 是 h_t 的权重矩阵； b_h 是偏差； W_h 和 b_h 的值在训练过程中会有所不同； e_i 的范围是 $(-1, 1)$ ，最后采用 RMSProp 反向传播对参数进行优化^[28-29]。

1.4 模型参数

1.4.1 本文模型

本实验选择的是两个一维的 CNN 卷积核层：第一个 CNN 设置 filters 参数为 16，kernel_size 参数为 3，padding 参数为 same，激活函数为 relu 函数；第二个 CNN 设置 filters 参数为 32，kernel_size 参数为 3，padding 参数为 same，激活函数为 relu 函数。LSTM 层设置 units 参数为 32，激活函数选择默认的 sigmoid 函数和 tanh 函数(双曲正切激活函数)。

本文采用的 SOM 算法，迭代次数为 300 次，每次迭代时的样本数量为 30，输出层设置为一个 2×2 的矩阵，学习速率 $\eta(t)$ 设置为 $e^{-n/(t+2)}$ ，其中 n 为拓扑距离， t 为第 t 步迭代。

1.4.2 对比模型

本文采用的 MLP 模型，第一个隐藏层设置 64 个节点，第二个隐藏层设置 32 个节点，激活函数使用 logistic 函数，梯度下降方法使用 adam，惩罚系数设置为 0.000 1，迭代次数为 800 次。LSTM 对比实验模型设置 units 参数为 32，激活函数选择默认的 sigmoid 函数和 tanh 函数。

1.4.3 时间序列步长

本文实验 7.5 min 时间间隔的光伏数据选取的步长为 8；15 min 时间间隔选取的步长为 14；30 min 时间间隔选取的步长为 8，如图 6 所示。

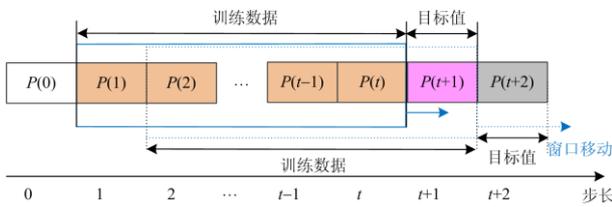


图 6 步长与训练数据、目标值的关系
Fig. 6 Relationship of time step, training data and target value

1.5 预测阶段

根据训练阶段的结果得到了 4 种具有不同月份的预测模型。在预测阶段,使用 2017 年至 2018 年的 AC2 数据进行测试。将每个月的测试数据制成一个数据集,得到 12 个数据集。然后根据每个数据集的月份选择合适的预测模型进行预测,结果如图 7 所示。在完成预测后,再根据测试集中的最大和最小光伏功率值对预测结果进行反归一化处理,最后得到光伏功率预测结果。

2 实验结果

在这项研究中,采用平均绝对百分比误差(MAPE),均方根误差(RMSE)和平均绝对误差(MAE)评估模型的预测能力,如式(15)一式(17)所示。

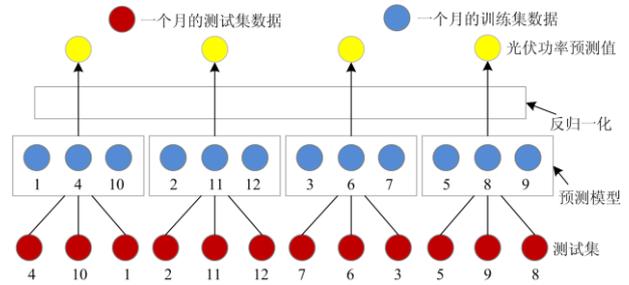


图 7 预测阶段的结构

Fig. 7 Structure of prediction stage

$$M_{MAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|x_{model,i} - x_{actual,i}|}{x_{actual,i}} \quad (15)$$

$$R_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_{model,i} - x_{actual,i})^2} \quad (16)$$

$$M_{MAE} = \frac{1}{n} \sum_{i=1}^n |x_{model,i} - x_{actual,i}| \quad (17)$$

实验结果比较了 LSTM 和 Attention 的组合模型(Attention-LSTM, ALSTM)、本文所提出的模型、MLP 和 LSTM 模型。其中表 2—表 10 中分别列出了预测时间间隔为 7.5 min、15 min、30 min 的测试集的 MAPE、RMSE 和 MAE 的误差结果。

表 2 预测时间间隔为 7.5 min 的测试集的 MAPE 结果

Table 2 MAPE results for test set of data when predicting time interval is 7.5 min

时间间隔	对比模型	2017.10	2017.11	2017.12	2018.1	2018.2	2018.3	2018.4	2018.5	2018.6	2018.7	2018.8	2018.9	平均
7.5 min	MLP	22.15	20.07	23.05	25.62	18.10	24.97	26.00	23.19	28.39	25.08	22.18	20.03	23.11
	LSTM	23.87	21.42	20.96	28.76	16.63	28.96	20.99	31.19	40.02	20.21	22.18	21.73	24.61
	ALSTM	21.64	22.44	21.44	28.16	23.52	24.55	18.43	17.82	32.79	25.46	29.05	19.78	23.32
	本文模型	19.95	16.76	20.79	25.01	16.90	19.29	15.84	16.83	17.21	22.20	19.88	18.69	18.82

表 3 预测时间间隔为 15 min 的测试集的 MAPE 结果

Table 3 MAPE results for test set of data when predicting time interval is 15 min

时间间隔	对比模型	2017.10	2017.11	2017.12	2018.1	2018.2	2018.3	2018.4	2018.5	2018.6	2018.7	2018.8	2018.9	平均
15 min	MLP	30.19	24.41	26.42	28.58	20.63	37.38	47.40	40.80	53.70	38.39	31.30	27.10	34.17
	LSTM	23.42	21.47	23.74	27.51	17.74	23.62	22.63	21.21	28.95	28.72	19.00	18.64	22.75
	ALSTM	20.30	23.08	22.40	28.38	20.40	29.96	29.69	20.53	68.64	47.60	24.06	22.49	28.82
	本文模型	22.69	20.32	26.51	28.04	21.06	28.17	28.61	25.12	18.23	25.44	23.87	20.89	23.79

表 4 预测时间间隔为 30 min 的测试集的 MAPE 结果

Table 4 MAPE results for test set of data when predicting time interval is 30 min

时间间隔	对比模型	2017.10	2017.11	2017.12	2018.1	2018.2	2018.3	2018.4	2018.5	2018.6	2018.7	2018.8	2018.9	平均
30 min	MLP	33.09	35.15	36.98	37.68	28.49	33.44	28.85	28.92	30.17	35.92	32.78	30.65	32.57
	LSTM	37.75	41.62	38.86	38.42	41.45	36.07	36.34	30.06	37.90	39.01	32.59	40.96	37.39
	ALSTM	25.67	29.86	37.76	42.77	33.89	30.41	57.01	28.64	30.09	30.71	37.50	35.79	34.18
	本文模型	32.62	29.59	29.32	32.88	23.50	33.38	34.87	31.34	45.62	30.19	31.84	32.62	32.39

表 5 预测时间间隔为 7.5 min 的测试集的 RMSE 结果

Table 5 RMSE results for test set of data when predicting time interval is 7.5 min

时间间隔	对比模型	2017.10	2017.11	2017.12	2018.1	2018.2	2018.3	2018.4	2018.5	2018.6	2018.7	2018.8	2018.9	平均
7.5 min	MLP	1.39	1.58	2.09	2.16	1.23	1.07	0.63	0.72	0.69	1.25	1.10	1.45	1.32
	LSTM	1.45	1.63	2.16	2.20	1.29	1.10	0.63	0.81	0.78	1.30	1.15	1.50	1.37
	ALSTM	1.60	1.75	2.16	2.36	1.33	1.10	0.69	0.81	0.71	1.34	1.17	1.63	1.42
	本文模型	1.44	1.52	2.08	2.32	1.23	1.10	0.63	0.65	0.70	1.36	1.24	1.40	1.30

表 6 预测时间间隔为 15 min 的测试集的 RMSE 结果

Table 6 RMSE results for test set of data when predicting time interval is 15 min

时间间隔	对比模型	2017.10	2017.11	2017.12	2018.1	2018.2	2018.3	2018.4	2018.5	2018.6	2018.7	2018.8	2018.9	平均
15 min	MLP	1.42	1.60	2.12	2.19	1.22	1.12	0.77	0.82	0.82	1.29	1.16	1.47	1.37
	LSTM	1.63	1.94	2.51	2.44	1.45	1.16	0.69	0.83	0.73	1.56	1.17	1.61	1.53
	ALSTM	1.54	1.90	2.38	2.49	1.74	1.19	0.71	0.77	0.96	1.61	1.25	1.69	1.55
	本文模型	1.57	1.78	1.47	1.86	1.47	1.21	0.75	0.90	0.87	1.45	1.29	1.62	1.40

表 7 预测时间间隔为 30 min 的测试集的 RMSE 结果

Table 7 RMSE results for test set of data when predicting time interval is 30 min

时间间隔	对比模型	2017.10	2017.11	2017.12	2018.1	2018.2	2018.3	2018.4	2018.5	2018.6	2018.7	2018.8	2018.9	平均
30 min	MLP	2.23	2.74	2.91	3.29	1.84	1.56	0.94	1.22	1.10	1.96	1.83	2.03	2.02
	LSTM	3.10	3.95	4.13	3.72	3.52	2.01	1.46	1.64	1.19	2.32	2.52	3.51	2.89
	ALSTM	1.80	2.95	3.78	3.91	2.66	1.19	0.94	0.99	0.76	2.06	1.46	3.18	2.22
	本文模型	2.26	2.29	2.95	3.12	1.71	1.92	1.00	0.94	0.96	1.71	1.69	2.71	2.04

表 8 预测时间间隔为 7.5 min 的测试集的 MAE 结果

Table 8 MAE results for test set of data when predicting time interval is 7.5 min

时间间隔	对比模型	2017.10	2017.11	2017.12	2018.1	2018.2	2018.3	2018.4	2018.5	2018.6	2018.7	2018.8	2018.9	平均
7.5 min	MLP	0.829	0.88	1.15	1.36	0.70	0.61	0.39	0.42	0.39	0.72	0.67	0.83	0.72
	LSTM	0.89	0.95	1.21	1.47	0.74	0.67	0.35	0.52	0.53	0.74	0.69	0.91	0.78
	ALSTM	1.049	1.12	1.22	1.56	0.84	0.62	0.39	0.45	0.44	0.83	0.77	1.05	0.83
	本文模型	0.85	0.84	1.25	1.55	0.78	0.57	0.32	0.40	0.33	0.81	0.80	0.88	0.70

表 9 预测时间间隔为 15 min 的测试集的 MAE 结果

Table 9 MAE results for test set of data when predicting time interval is 15 min

时间间隔	对比模型	2017.10	2017.11	2017.12	2018.1	2018.2	2018.3	2018.4	2018.5	2018.6	2018.7	2018.8	2018.9	平均
15 min	MLP	0.91	0.92	1.17	1.38	0.69	0.73	0.58	0.58	0.61	0.84	0.75	0.91	0.82
	LSTM	1.05	1.25	1.61	1.61	0.97	0.67	0.41	0.49	0.42	0.97	0.70	1.02	0.90
	ALSTM	0.95	1.24	1.42	1.65	1.25	0.76	0.47	0.44	0.78	1.16	0.82	1.12	0.95
	本文模型	1.022	1.20	1.53	1.55	1.16	0.74	0.49	0.54	0.42	0.81	0.83	0.91	0.85

表 10 预测时间间隔为 30 min 的测试集的 MAE 结果

Table 10 MAE results for test set of data when predicting time interval is 30 min

时间间隔	对比模型	2017.10	2017.11	2017.12	2018.1	2018.2	2018.3	2018.4	2018.5	2018.6	2018.7	2018.8	2018.9	平均
30 min	MLP	1.58	2.02	2.09	2.29	1.35	1.03	0.55	0.73	0.57	1.26	1.30	1.47	1.32
	LSTM	2.18	2.98	3.00	2.73	2.78	1.27	0.86	0.97	0.67	1.51	1.73	2.60	1.90
	ALSTM	1.19	2.24	2.99	3.16	2.23	0.76	0.77	0.66	0.46	1.39	1.12	2.43	1.47
	本文模型	1.64	1.66	2.07	2.29	1.30	1.39	0.67	0.64	0.68	1.10	1.23	2.13	1.38

由表 2—表 10 和图 8—图 10 的实验数据得到, 所提出的模型在 RMSE 误差指标上具有良好的性能。当存在大量异常数据时, RMSE 指标值会变得很大, 这表明通过使用建议的模型可以减少预测的异常数据。在 7.5 min 内的时间间隔预测中, 所提出的模型在 MAE 指标方面具有比其他模型更好的性能。从以上数据可以得出, 7.5 min 内的间隔预测中所提出的模型在 MAPE 误差值对比中比其他模型小 4.29~5.79, 在 RMSE 误

差值对比中小 0.02~0.12, 在 MAE 误差值对比中小 0.02~0.13, 精度明显提高。

本文模型在光伏数据 7.5 min 时间间隔预测上具有良好的表现, 在 30 min 时间间隔上预测表现不好, 其主要原因在于本文使用的 30 min 时间间隔实验数据为 7.5 min 时间间隔实验数据的 1/4, 大部分的光伏数据点被移除, 其中包括反映功率变化的数据点, 其次模型使用到注意力机制算法, 通过实验得到预测值, 反向地不断更新权

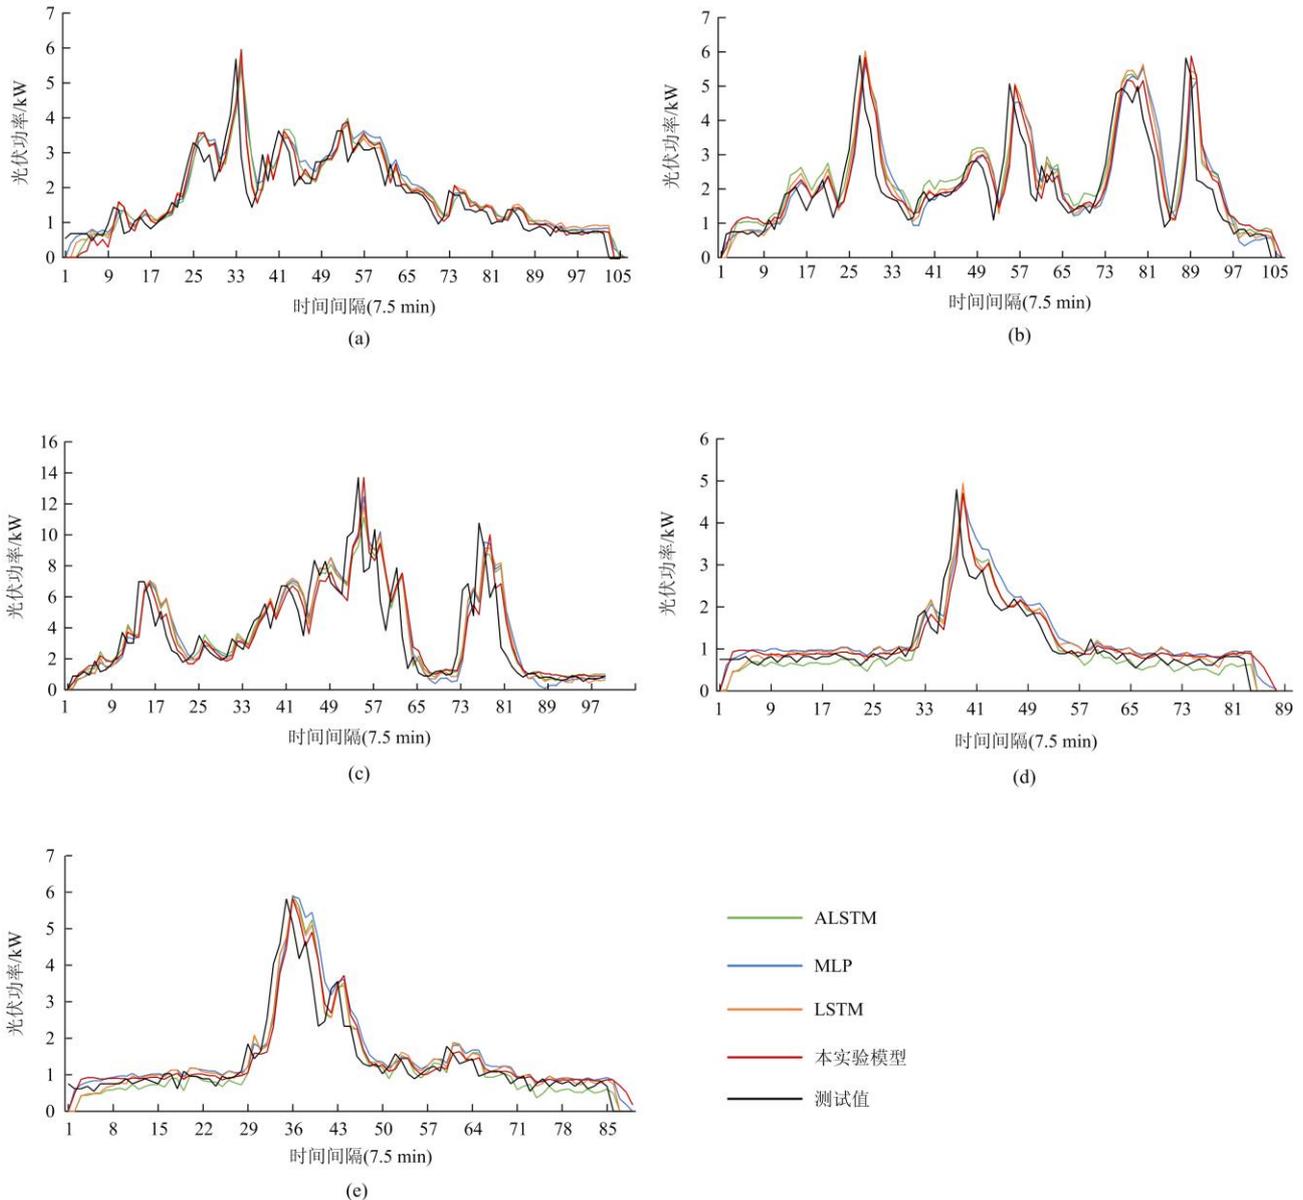


图 8 预测时间间隔为 7.5 min 的光伏发电功率预测结果

Fig. 8 PV generating power forecast result when predicting time interval is 7.5 min

重, 以达到注意力机制的最优权重, 这种算法可以将预测结果更加拟合于训练集数据的变化。由于光伏数据具有波动性, 一旦大部分反映功率变化的训练数据被删除, 训练集的数据信息与预测集的数据信息相差过大, 此算法模型的预测能力与其他传统模型相比较差。最后, 7.5 min 每天的

训练数据为 192 个数据点, 而 30 min 每天的训练数据点为 48 个, 在聚类实验中, 并没有将 7.5 min 实验数据的聚类结果作为 30 min 聚类实验的结果, 30 min 时间间隔的聚类实验数据少了大部分信息, 训练模型会因为聚类实验结果影响到预测模型的预测能力, 降低了预测精度。

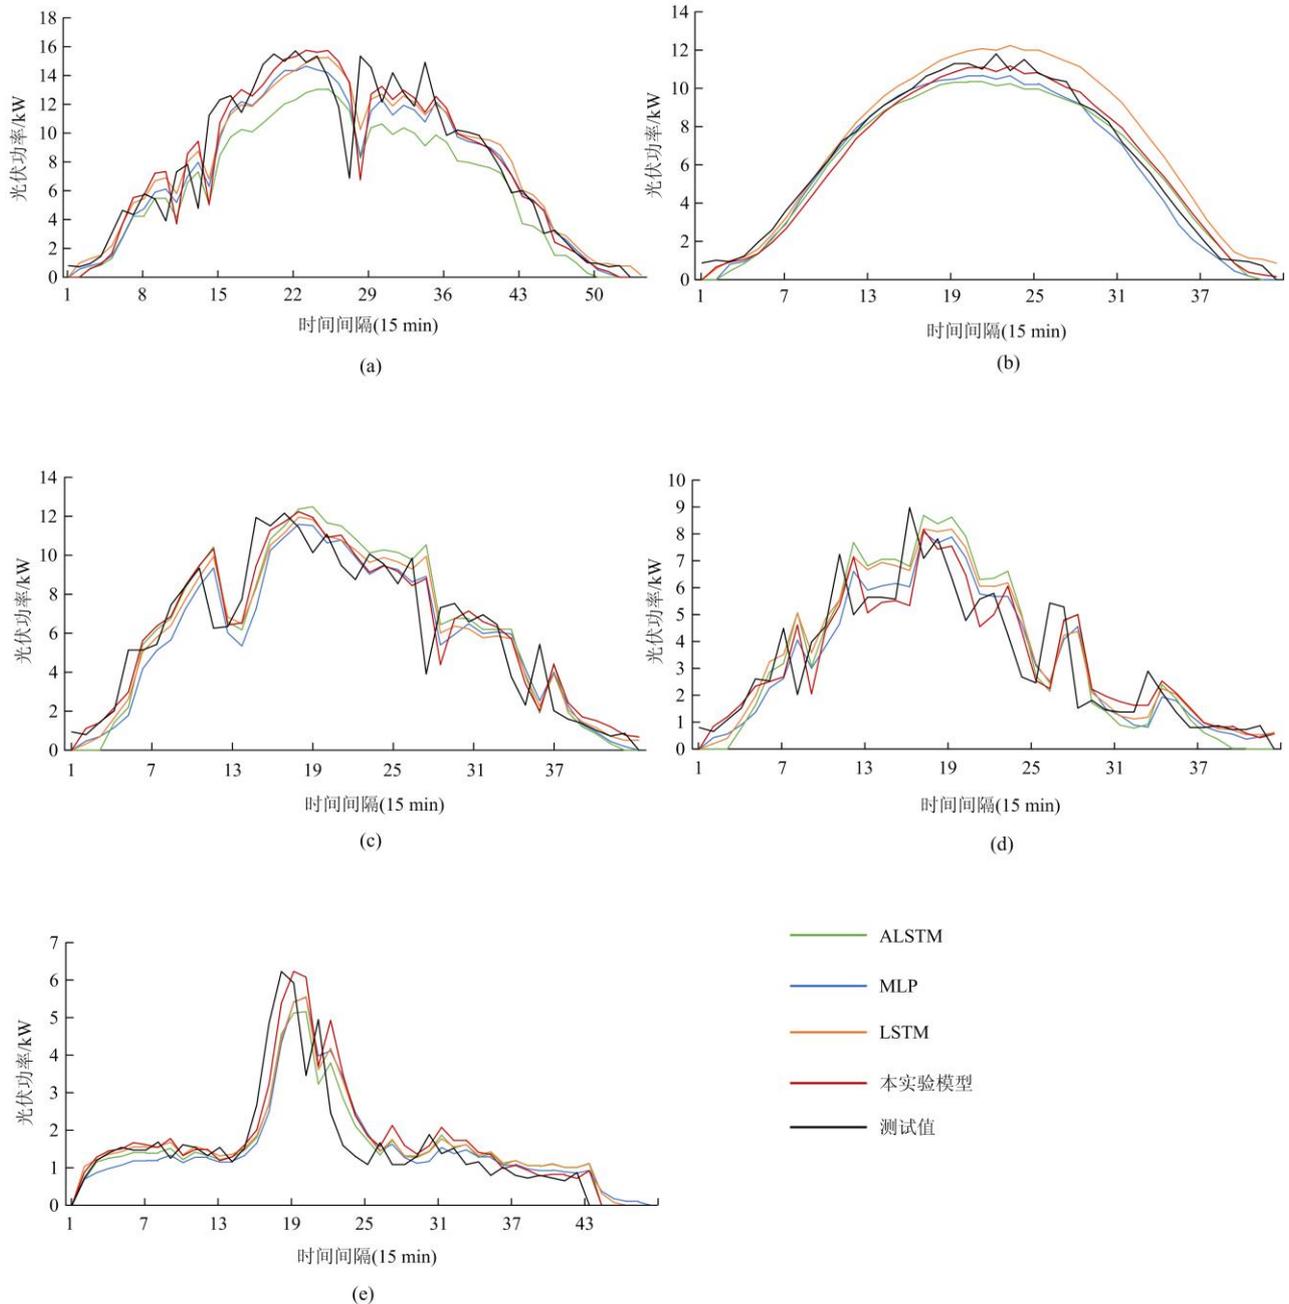


图 9 预测时间间隔为 15 min 的光伏发电功率预测结果

Fig. 9 PV generating power forecast result when predicting time interval is 15 min

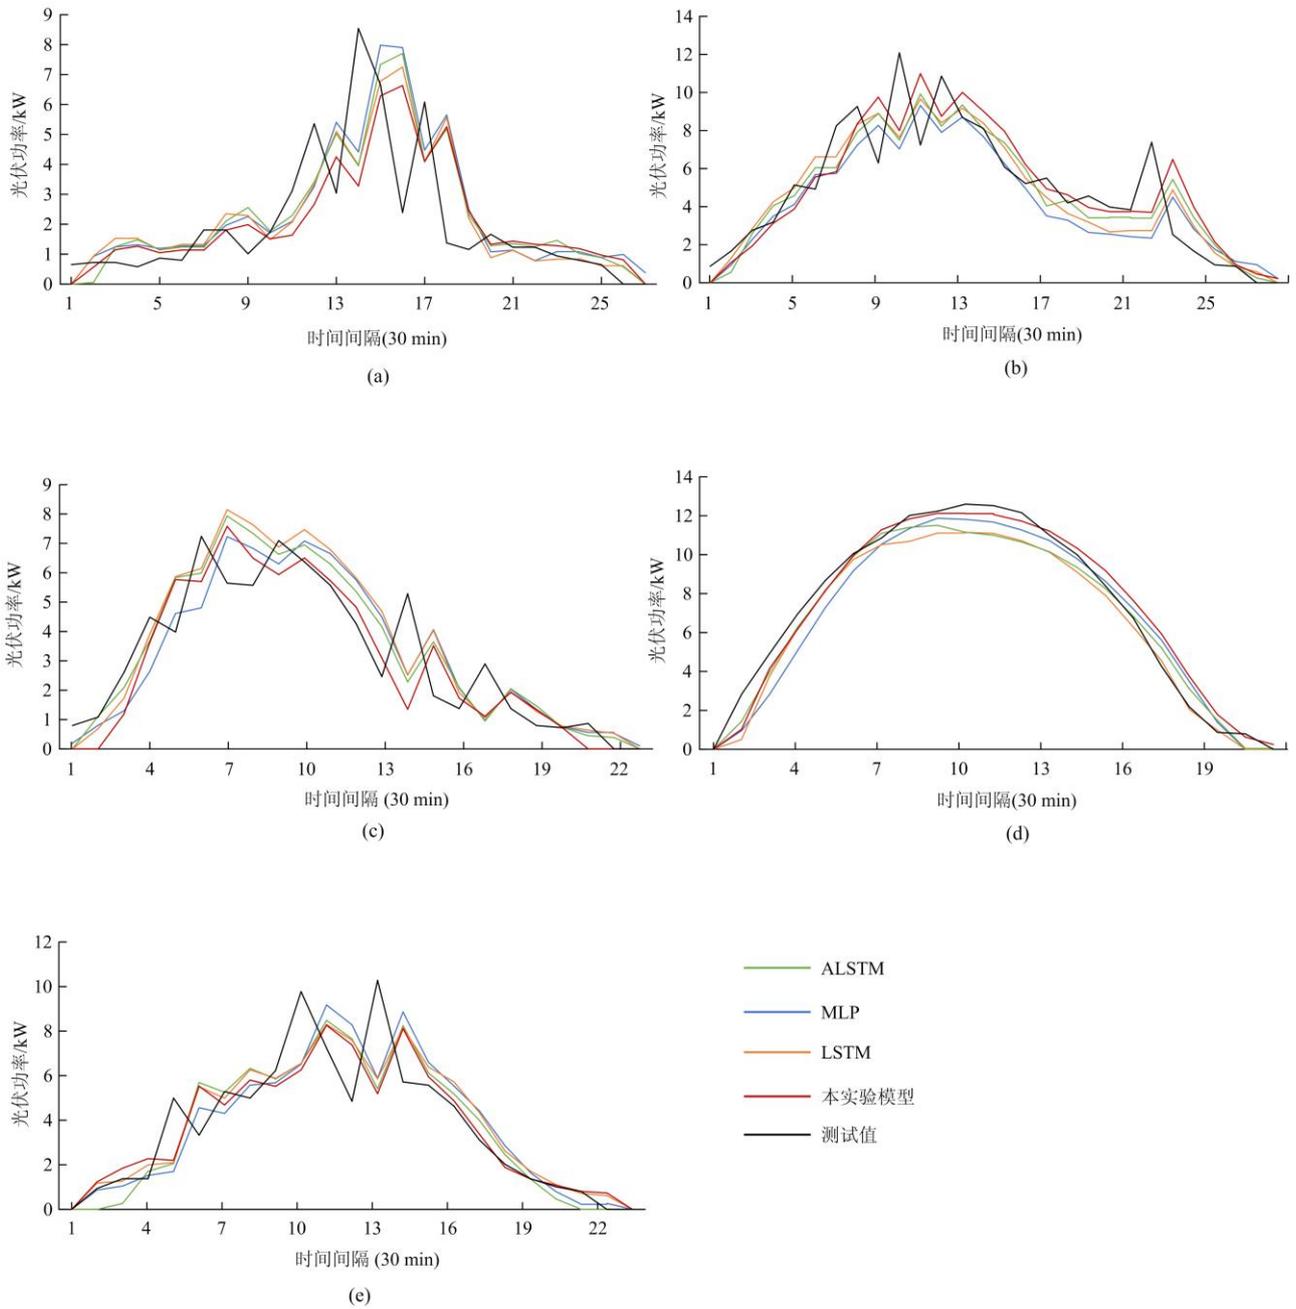


图 10 预测时间间隔为 30 min 的光伏发电功率预测结果

Fig. 10 PV generating power forecast result when predicting time interval is 30 min

3 结论

本文提出的基于季节类别的混合深度学习模型与传统模型不同，该算法可以训练和预测没有天气属性的数据，当获得的数据缺少有关光伏面板周围环境的数据时，该方法可用于寻找潜在的天气类别进行训练和预测，从而大大减少了数据收集的工作量。

由以上实验比较的结果表明，研究中提出的混合深度学习预测模型在预测时间间隔小于 7.5 min 的光伏功率输出时，具有很明显的优势。

参考文献

[1] NEMA P, NEMA R K, RANGNEKAR S. A current and future state of art development of hybrid energy system using wind and PV-solar: a review[J]. Renewable &

- Sustainable Energy Reviews, 2009, 13(8): 2096-2103.
- [2] 余贻鑫. 智能电网实施的紧迫性和长期性[J]. 电力系统保护与控制, 2019, 47(17): 1-5.
YU Yixin. Urgency and long-term nature of smart grid implementation[J]. Power System Protection and Control, 2019, 47(17): 1-5.
- [3] 苗长越, 王维庆, 王海云, 等. 光伏接入对系统小干扰稳定的影响研究[J]. 高压电器, 2019, 55(7): 211-215.
MIAO Changyue, WANG Weiqing, WANG Haiyun, et al. Research of the influence of photovoltaic access on small disturbance stability of the system[J]. High Voltage Apparatus, 2019, 55(7): 211-215.
- [4] 张军, 张新源, 吴俊兴, 等. 考虑户用光伏发电的家庭能量管理方法研究[J]. 电网与清洁能源, 2020, 36(2): 117-123.
ZHANG Jun, ZHANG Xinyuan, WU Junxing, et al. Study on household energy management methods considering household photovoltaic power generation[J]. Power System and Clean Energy, 2020, 36(2): 117-123.
- [5] 张旻, 李天喆, 张容进, 等. 基于信息融合的动态神经网络光伏功率预测[J]. 电力科学与技术学报, 2020, 35(3): 68-73.
ZHANG Min, LI Tianzhe, ZHANG Rongjin, et al. Photovoltaic power forecasting based on information fusion theory[J]. Journal of Electric Power Science and Technology, 2020, 35(3): 68-73.
- [6] 樊安洁, 高山, 方济城, 等. 基于多链 MCMC 方法的光伏出力序列预测研究[J]. 电力工程技术, 2018, 37(6): 55-61.
FAN Anjie, GAO Shan, FANG Jicheng, et al. A PV power time series generating method considering correlation characteristics based on multi Markov chain Monte Carlo method[J]. Electric Power Engineering Technology, 2018, 37(6): 55-61.
- [7] 吴忠强, 于丹琦, 康晓华. 改进鸡群算法在光伏系统 MPPT 中的应用[J]. 太阳能学报, 2019, 40(6): 1589-1598.
WU Zhongqiang, YU Danqi, KANG Xiaohua. Application of improved chicken swarm optimization for MPPT in photovoltaic system[J]. Acta Energetica Solaris Sinica, 2019, 40(6): 1589-1598.
- [8] 任林涛, 汪飞, 杨柳柳, 等. 分布式光伏电站系统效率模型分析与研究[J]. 太阳能学报, 2019, 40(6): 1599-1606.
REN Lintao, WANG Fei, YANG Liuliu, et al. Analysis and research on efficiency models of distributed PV power system[J]. Acta Energetica Solaris Sinica, 2019, 40(6): 1599-1606.
- [9] 李正明, 梁彩霞, 王满商. 基于 PSO-DBN 神经网络的光伏短期发电出力预测[J]. 电力系统保护与控制, 2020, 48(8): 149-154.
LI Zhengming, LIANG Caixia, WANG Manshang. Short-term power generation output prediction based on a PSO-DBN neural network[J]. Power System Protection and Control, 2020, 48(8): 149-154.
- [10] ZHANG Xiaoning, FANG Fang, LIU Jizhen. Weather-classification-MARS-based photovoltaic power forecasting for energy imbalance market[J]. IEEE Transactions on Industrial Electronics, 2019, 66(11): 8692-8702.
- [11] 王志豪, 李自成, 王后能, 等. 基于 RBF 神经网络的光伏系统 MPPT 研究[J]. 电力系统保护与控制, 2020, 48(6): 85-91.
WANG Zhihao, LI Zicheng, WANG Houneng, et al. MPPT study of solar PV power system based on RBF neural network algorithm[J]. Power System Protection and Control, 2020, 48(6): 85-91.
- [12] GAO Mingming, LI Jianjing, HONG Feng, et al. Short-term forecasting of power production in a large-scale photovoltaic plant based on LSTM[J]. Applied Science-Basel, 2019, 9(15): 14-24.
- [13] XU Yang, WANG Guojun, REN Ju, et al. An adaptive and configurable protection framework against android privilege escalation threats[J]. Future Generation Computer Systems, 2019, 92: 210-224.
- [14] ZHONG Chaowen, YAN Ke, DAI Yuting, et al. Energy efficiency solutions for buildings: automated fault diagnosis of air handling units using generative adversarial networks[J]. Energies, 2019, 12(3).
- [15] DU Yang, YAN Ke, REN Zixiao, et al. Designing localized MPPT for PV systems using fuzzy-weighted extreme learning machine[J]. Energies, 2018, 11(10).
- [16] 张静, 褚晓红, 黄学安, 等. 一种基于加权马尔科夫链修正的 SVM 光伏出力预测模型[J]. 电力系统保护与控制, 2019, 47(19): 63-68.
ZHANG Jing, CHU Xiaohong, HUANG Xue'an, et al. A model for photovoltaic output prediction based on SVM modified by weighted Markov chain[J]. Power System Protection and Control, 2019, 47(19): 63-68.
- [17] 张俊, 贺旭, 陆春良, 等. 基于数值天气预报的光伏功率短期预测分类组合算法[J]. 广东电力, 2019, 32(6): 55-60.
ZHANG Jun, HE Xu, LU Chunliang, et al. Classification and combination algorithm for photovoltaic power

- short-term forecasting based on numerical weather prediction[J]. Guangdong Electric Power, 2019, 32(6): 55-60.
- [18] JIMENEZ-PEREZ P F, MORA-LOPEZ L. Modeling and forecasting hourly global solar radiation using clustering and classification techniques[J]. Solar Energy, 2016, 135: 682-691.
- [19] YANG H T, HUANG C M, HUANG Y C, et al. A weather-based hybrid method for 1-day ahead hourly forecasting of PV power output[J]. IEEE Transactions on Sustainable Energy, 2014, 5(3): 917-926.
- [20] VESANTO J, ALHONIEMI E. Clustering of the self-organizing map[J]. IEEE Transactions on Neural Networks, 2000, 11(3): 586-600.
- [21] BASHYAL S, VENAYAGAMOORTHY G K. Recognition of facial expressions using Gabor wavelets and learning vector quantization[J]. Engineering Applications of Artificial Intelligence, 2008, 21(7): 1056-1064.
- [22] HAN Yutong, WANG Ningbo, MA Ming, et al. A PV power interval forecasting based on seasonal model and nonparametric estimation algorithm[J]. Solar Energy, 2019, 184: 515-526.
- [23] 简献忠, 顾洪志, 王如志. 一种基于双通道 CNN 和 LSTM 的短期光伏功率预测方法[J]. 电力科学与工程, 2019, 35(5): 7-11.
- JIAN Xianzhong, GU Hongzhi, WANG Ruzhi. A short-term photovoltaic power prediction model based on dual-channel CNN and LSTM[J]. Electric Power Science and Engineering, 2019, 35(5): 7-11.
- [24] 张琦, 彭志平. 融合注意力机制和 CNN-GRNN 模型的读者情绪预测[J]. 计算机工程与应用, 2018, 54(13): 168-174.
- ZHANG Qi, PENG Zhiping. Attention-based convolutional-gated recurrent neural network for reader's emotion prediction[J]. Computer Engineering and Applications, 2018, 54(13): 168-174.
- [25] 张希. 光伏发电在微电网中接入及动态特性研究[J]. 电力设备管理, 2020(7): 126-129.
- ZHANG Xi. Research on dynamic characteristic and integration of photovoltaic in microgrids[J]. Power Equipment Management, 2020(7): 126-129.
- [26] 蒋建东, 余沅, 董存, 等. 基于 PSO 与 ELM 组合算法的短期光伏发电功率预测模型[J]. 郑州大学学报: 理学版, 2019, 51(3): 120-126.
- JIANG Jiandong, YU Feng, DONG Cun, et al. A short-term Photovoltaic power forecasting model based on PSO and ELM combined algorithm[J]. Journal of Zhengzhou University: Natural Science Edition, 2019, 51(3): 120-126.
- [27] SHAO Bilin, HU Xiaoli, BIAN Genqing, et al. A multichannel LSTM-CNN method for fault diagnosis of chemical process[J]. Mathematical Problems in Engineering, 2019(3): 1-14.
- [28] CHEN Chen, HUA Zhengchun, ZHANG Ruiqi, et al. Automated arrhythmia classification based on a combination network of CNN and LSTM[J]. Biomedical Signal Processing and Control, 2020, 57: 1-10.
- [29] CAMPBELL J, BEN A H, ANG M H, et al. Traffic light status detection using movement patterns of vehicles[C] // 2016 IEEE 19th international conference on intelligent transportation systems (ITSC), November 1-4, 2016, Rio de Janeiro, Brazil: 283-288.

收稿日期: 2020-12-03; 修回日期: 2021-03-05

作者简介:

周杭霞(1963—), 女, 通信作者, 硕士生导师, 教授, 研究方向为智慧能源、模式识别与数据挖掘; E-mail: zhx@cjlu.edu.cn

刘倩(1988—), 女, 硕士, 助理实验师, 研究方向为大数据、智能算法、机器学习等; E-mail: liuqian235@cjlu.edu.cn

胡强(1994—), 男, 硕士研究生, 研究方向为机器学习、大数据分析。E-mail: p1903085207@cjlu.edu.cn

(编辑 姜新丽)