

DOI: 10.19666/j.rlfed.202212235

基于组合神经网络的分布式光伏 超短期功率预测方法

杨锡运¹, 马文兵¹, 彭 琰², 孟令卓超¹, 王晨旭², 马骏超²

(1.华北电力大学控制与计算机工程学院, 北京 102206;

2.国网浙江省电力有限公司电力科学研究院, 浙江 杭州 310014)

[摘 要] 分布式光伏电站在电力系统中的渗透率逐年升高, 为保障电网安全稳定运行, 提出一种基于组合神经网络的分布式光伏超短期功率预测方法。首先利用一维卷积神经网络(1DCNN)与长短期记忆(LSTM)神经网络构建 1DCNN&1DCNN-LSTM 组合神经网络模型, 获取多位置数值天气预报(NWP)信息与历史功率信息; 然后利用组合神经网络模型进行空间相关性光伏功率预测与时间序列预测, 并在组合神经网络模型中加入全连接神经网络(FCNN), 利用全连接神经网络对 2 种预测结果进行学习与权重分配, 实现了分布式光伏发电功率的超短期预测。采用河北某光伏电站实测数据进行验证, 验证结果表明, 该方法能够有效提高分布式光伏预测精度, 具有一定的实用价值。

[关 键 词] 分布式光伏; 超短期功率预测; LSTM; 1DCNN; 深度学习

[引用本文格式] 杨锡运, 马文兵, 彭琰, 等. 基于组合神经网络的分布式光伏超短期功率预测方法[J]. 热力发电, 2023, 52(8): 162-171. YANG Xiyun, MA Wenbing, PENG Yan, et al Distributed photovoltaic ultra-short-term power prediction method based on combined neural network[J]. Thermal Power Generation, 2023, 52(8): 162-171.

Distributed photovoltaic ultra-short-term power prediction method based on combined neural network

YANG Xiyun¹, MA Wenbing¹, PENG Yan², MENG Lingzhuochao¹, WANG Chenxu², MA Junchao²

(1.School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China;

2.Electric Power Research Institute of State Grid Zhejiang Electric Power Co., Ltd., Hangzhou 310014, China)

Abstract: The penetration rate of distributed photovoltaic power stations in the power system is increasing year by year, to ensure the safe and stable operation of the power grid, a distributed photovoltaic ultra-short-term power prediction method based on combined neural networks is proposed. Firstly, a 1DCNN&1DCNN-LSTM combined neural network model is constructed by using 1D convolutional neural network (1DCNN) and long short-term memory (LSTM) neural networks, to obtain multi location numerical weather prediction (NWP) information and historical power information, using combined neural network model for spatially correlated photovoltaic power prediction and time series prediction; and a fully connected neural network (FCNN) is added to the combined neural network model, which is used to learn and assign weights to the two prediction results, achieving ultra-short-term prediction of distributed photovoltaic power generation. The validation was conducted using measured data from a photovoltaic power station in Hebei, and the results showed that this method can effectively improve the accuracy of distributed photovoltaic prediction and has certain practical value.

Key words: distributed photovoltaic; ultra-short-term power prediction; LSTM; 1DCNN; deep learning

我国于 2020 年 9 月明确提出力争 2030 年前实现“碳达峰”与 2060 年前“碳中和”的“双碳”目

标, 在“双碳”目标下, 新能源发电将加快发展^[1]。2021 年新增光伏并网 54.88 GW, 分布式光伏新增

收稿日期: 2022-12-02

基金项目: 国网浙江省电力有限公司科技项目(5211DS220009)

Supported by: Science and Technology Project of State Grid Zhejiang Electric Power Co., Ltd. (5211DS220009)

第一作者简介: 杨锡运(1973), 女, 教授, 博士生导师, 主要研究方向为新能源发电控制, yangxiyun916@sohu.com。

通信作者简介: 马文兵(1997), 男, 硕士研究生, 主要研究方向为新能源发电与机器学习方面, 1635352191@qq.com。

装机 29.28 GW^[2], 占据光伏应用的半壁江山。然而, 由于光伏输出功率具有波动性与间歇性, 在电力系统方面, 既要提高光伏电站运营效率, 又要同时保证电力系统在接入光伏后的安全性与经济性, 因此只有准确预测光伏出力, 才能降低光伏并网所带来的巨大冲击, 进而协助调度部门调整运行方式。

相较于集中式光伏电站, 分布式光伏电站处于成本考虑, 往往不设置气象测量装置, 缺乏预测所需的实测辐照与天气预报信息^[3], 这将大大增加光伏出力预测难度。而在同一地区影响光伏出力的天气辐照度较为接近, 因此基于空间相关性, 借助临近集中式光伏电站的完备信息来预测分布式光伏出力是一种可行方案^[4]。

目前, 集中式光伏功率预测方法相对成熟。研究集中式光伏功率超短期(0~4 h)预测方法与短期(未来 1~2 天)预测方法, 可以作为分布式光伏功率预测方法的参考。集中式光伏功率预测主要分为物理模型预测方法^[5]与数据驱动预测方法。物理模型预测方法是对太阳光照强度与光伏组件的物理特性进行数学方程建模, 利用数值天气预报(numerical weather prediction, NWP)得到太阳辐照度、温度、雨量、风速等信息, 继而对光伏发电输出功率值进行预测的方法。这类预测方法通常还要求光伏发电系统的详细参数、地理位置信息、环境信息等诸多参数^[6]。然而, 由于分布式光伏电站运维水平、组件工艺等因素限制, 一般难以获得硬件设施的具体参数, 难以开展功率预测工作。数据驱动方法以光电设备的输出数据为研究对象, 采用时间序列预测方法^[7-9]、神经网络算法^[10-13]等对光伏功率进行预测。数据驱动方法以光伏设备的出力特性为建模的主要考虑因素, 具有良好的非线性逼近能力, 不需事先知道光伏设备的地理位置和光伏模块的参数, 可将此方法扩展到分布式光伏电站功率预测中。

在超短期光伏功率预测方面, 文献[14]通过将深度信念网络与 T-S 模糊模型组合, 并采用遗传算法赋予权重, 提高了光伏功率预测精度, 但是模型间仅用数据量较少的测试集去分配权重, 模型间权重难以合理分配, 致使组合模型泛化性较低。文献[15]通过对地面拍摄的云图通过数字图像处理技术提取特征, 结合径向基神经网络预测光伏功率出力, 然而由于成本原因, 分布式光伏缺乏地面云图拍摄装置。文献[16]首先使用卫星遥感数据并基于 Res-UNet 对未来短波辐射进行预测, 利用长短时记

忆(long short-term memory, LSTM)神经网络模型预测光伏出力, 但其缺乏对于历史数据的深度挖掘。文献[17]使用卫星遥感图像, 利用多光谱融合、图像预测和双层生成式采样等方式进行光伏预测, 在 1.5 h 及以上的超短期光伏功率预测有着优异表现, 但在更低尺度下的超短期预测精度不佳。文献[18]将一维卷积神经网络(1D convolutional neural network, 1DCNN)与 LSTM 神经网络结合, 并使用遗传算法进行模型优化, 利用历史数据作为输入, 进行下一时刻的功率预测, 有效提高了预测精度, 但仅依靠历史数据, 预测精度会随预测时间增长迅速降低, 文献[19]利用 EMD 将环境监测数据进行分解, 再利用 PCA 降低输入参数的维度, 最后利用 LSTM 神经网络进行预测, 提高了下一时刻功率预测的精度, 但并不适用于仅存在功率数据的分布式光伏。

基于以上特点, 本文提出一种基于组合神经网络的分布式光伏超短期预测方法, 首先, 利用一维卷积神经网络与长短时记忆神经网络构建组合神经网络模型, 考虑与临近电站的空间相关性, 通过获取多个临近光伏电站的 NWP 水平辐照度预报信息, 利用 1DCNN 的数据挖掘能力, 提取未来水平辐照度变化信息, 进行空间相关性功率预测; 将 1DCNN 与 LSTM 相结合, 利用 1DCNN 对历史功率进行数据空间重构, 结合 LSTM 提取数据的长期依赖特征, 实现对历史功率的深度挖掘, 进行时间序列预测; 最后将空间相关性功率预测与时间序列预测结果进行拼接组合, 利用全连接神经网络对 2 种预测结果进行学习与权重分配, 实现不同时间尺度下光伏功率预测, 并在河北某光伏电站验证了本文方法可行性。

1 时空关联分析

1.1 灰色关联度模型

灰色系统理论通过确定参考序列与比较序列的几何相似程度判断其关联性^[20], 曲线越接近则关联度越高, 反之就越小。本文通过灰色关联度模型从时间角度分析预测电站主要影响因素, 从空间角度分析临近电站主要影响因素与预测电站关联程度。灰色关联度模型具体方法如下。

1) 比较序列和参考序列

为了对不同的影响因素进行评价, 首先确定参考序列。一般规定参考序列 \tilde{X}_0 包括 m 个元素, 可

表示为 $\{\tilde{x}_0(1), \tilde{x}_0(2), \dots, \tilde{x}_0(m)\}$ ，一般把 n 个比较序列记为 $\tilde{X}_1, \tilde{X}_2, \dots, \tilde{X}_n$ ，每个比较序列 $\tilde{X}_i = \{\tilde{x}_i(1), \tilde{x}_i(2), \dots, \tilde{x}_i(m)\}$ ， $i=1, 2, \dots, n$ 。

2) 均值化

将序列的数据除以均值，将不同量级的数据均值化，均值化后参考序列 $X_0 = \{x_0(1), x_0(2), \dots, x_0(m)\}$ ，比较序列 X_1, X_2, \dots, X_n ， $X_i = \{x_i(1), x_i(2), \dots, x_i(m)\}$ ， $i=1, 2, \dots, n$ 。

3) 确定关联系数和关联度

对于参考序列与比较序列，计算序列中对应元素之间的关联系数^[21]，计算公式为：

$$\zeta_i(k) = \frac{\min_{i=1}^n \min_{k=1}^m \Delta_i(k) + \eta \cdot \max_{i=1}^n \max_{k=1}^m \Delta_i(k)}{\Delta_i(k) + \eta \cdot \max_{i=1}^n \max_{k=1}^m \Delta_i(k)} \quad (1)$$

式中： $\zeta_i(k)$ 为第 i 个比较序列中第 k 个元素的关联系数； η 为分辨系数，其取值为 0~1，一般取值为 0.5^[21-22]； $\Delta_i(k) = |x_0(k) - x_i(k)|$ ，表示参考序列与比较序列对应元素的绝对差值。

关联度通过比较序列各元素关联系数后求均值给出，计算公式为：

$$R_{oi} = \frac{1}{m} \sum_{k=1}^m \zeta_i(k) \quad (2)$$

最终得出各比较序列的灰色关联度 R_{oi} 。

1.2 关联分析结果

本文数据来源于河北省 8 个光伏电站^[23]。8 个光伏电站位置分布如图 1 所示，提供数据有 NWP 数据（包括水平辐照度、直接辐照度、温度、湿度、风速风向、大气压力）和实测环境数据（包括水平辐照度、散射辐照度、温度、大气压力、风速风向）及电站功率数据。选取 2 号电站作为研究对象（容量为 20MW，历史最大功率为 17.607 MW），时间为 2018 年 7 月至 2019 年 6 月，数据时间间隔为 15 min。数据集提供了各变量的数值天气预报值和实测环境数据值，由于功率数据为实测数据，本文分析功率数据与实测环境数据中各因素的关联程度。

为保持 NWP 数据和实测环境数据的变量对应关系，同时考虑到风速、风向^[24]对光伏发电功率影响较小，因此仅对 2 号电站实测水平辐照度、温度、大气压力与电站功率数据进行灰色关联度分析。1、3 号电站距离 2 号电站的空间距离最近，选取为临近电站，同样分析其水平辐照度与 2 号电站功率关联度，结果见表 1。由表 1 可见，水平辐照度与功率的关联程度最高，为影响光伏出力最主要因素。

同时 1 号电站与 3 号电站的水平辐照度与 2 号电站功率存在很强的关联度，可以看出临近电站与预测电站间有很强的空间关联性。




图 1 电站位置分布

Fig.1 Location distribution of the power stations

表 1 各要素与 2 号光伏电站功率灰色关联度

Tab.1 Grey correlation degree between each element and the power of 2# photovoltaic power station

对象	辐照度	温度	大气压力	1 号电站辐照度	3 号电站辐照度
关联度	0.964 6	0.695 1	0.671 8	0.936 1	0.932 1

2 神经网络模型

2.1 一维卷积神经网络模型

1DCNN 是一种深度学习架构，其核心操作是卷积运算，1DCNN 通过建立多个滤波器提取输入数据的有效特征，对输入数据进行深度挖掘。不同于常规二维卷积神经网络，1DCNN 的输入通常为一维或二维数组（包含多个输入特征时），同时其卷积核仅在 1 个方向进行滑动^[25]（如时间序列对象仅在时间轴方向滑动）。目前，1DCNN 已经被应用于序列数据的提取、识别、可靠性诊断和预测方面。图 2 为 1DCNN 结构示意图。




图 2 1DCNN 结构示意图

Fig.2 Schematic diagram of 1DCNN structure

图 2 中: 输入层输入特征 $\mathbf{X}^l \in \mathbf{R}^{z_1 \times c_1}$; 卷积核 $\mathbf{W}^{l+1} \in \mathbf{R}^{k \times c_1}$; 卷积层输出特征 $\mathbf{X}^{l+1} \in \mathbf{R}^{z_2 \times c_2}$; l 为层间编号; z_1 和 z_2 分别为输入和输出特征的序列长度; c_1 为输入特征的通道数; c_2 为卷积核的个数, 同时决定了卷积层输出特征的通道数; k 为卷积核尺寸。

卷积运算: 利用卷积核对输入序列信号进行卷积运算, 提取相应的特征与重构样本空间特征。卷积后输出结果计算公式为:

$$\mathbf{X}_i^{l+1} = f(\mathbf{X}^l \otimes \mathbf{W}_i^{l+1} + \mathbf{b}_i^{l+1}), i \in \{1, 2, \dots, c_2\} \quad (3)$$

$$\mathbf{X}^{l+1} = \mathbf{X}_1^{l+1} \oplus \mathbf{X}_2^{l+1} \oplus \dots \oplus \mathbf{X}_{c_2}^{l+1} \quad (4)$$

式中: f 为激活函数; \otimes 为一维卷积运算符; $\mathbf{b}^{l+1} \in \mathbf{R}^{c_2}$ 为偏置项; \oplus 为矩阵拼接运算符。

可以看出 1DCNN 是由多个卷积核按照时间轴方向, 按照设定卷积步长滑动平移, 每一步由卷积核与对应元素加权求和, 再通过激活函数进行映射得到第 $l+1$ 层第 i 个特征通道 \mathbf{X}_i^{l+1} , 最后输出特征 \mathbf{X}^{l+1} 由各卷积核对应 \mathbf{X}_i^{l+1} 拼接而成, 并且 \mathbf{X}^{l+1} 的时间序列长度 z_2 满足:

$$z_2 = \frac{z_1 + 2p - k}{s} + 1 \quad (5)$$

式中: p 为卷积填充长度; s 为卷积步长。通过合理的设置 p 和 s , 可以避免序列长度 z_2 下降过快, 损失边缘信息。

2.2 长短时记忆神经网络模型

LSTM 是循环神经网络 (RNN) 的一种变体, 具有特殊的遗忘门、输入门、输出门结构, 解决了循环神经网络无法处理长时间依赖问题以及循环神经网络可能出现梯度爆炸与梯度消失问题^[26]。LSTM 神经网络具有对时间序列的长期记忆能力, 可以更好地提取时间序列的特征。分布式光伏输出功率作为具有较强时序相关性的时间序列数据, 为提取内在长期依赖特征, 选择 LSTM 神经网络进行预测。

LSTM 神经网络单元结构如图 3 所示。图 3 中: C_{t-1} 、 C_t 分别为 $t-1$ 、 t 时刻的细胞状态; h_{t-1} 、 h_t 分别为隐含层在 $t-1$ 、 t 时刻的状态, 细胞状态和隐含层状态分别包含着网络单元对时间序列信息的长时记忆和短时记忆; x_t 为 t 时刻的输入。

遗忘门决定从细胞状态遗忘的信息:

$$\mathbf{f}_t = \sigma(\mathbf{W}_f \cdot [\mathbf{h}_{t-1}, x_t] + \mathbf{b}_f) \quad (6)$$

输入门更新细胞状态的信息:

$$\mathbf{i}_t = \sigma(\mathbf{W}_i \cdot [\mathbf{h}_{t-1}, x_t] + \mathbf{b}_i) \quad (7)$$

$$\tilde{\mathbf{C}}_t = \tanh(\mathbf{W}_c \cdot [\mathbf{h}_{t-1}, x_t] + \mathbf{b}_c) \quad (8)$$

$$\mathbf{C}_t = \mathbf{f}_t \cdot \mathbf{C}_{t-1} + \mathbf{i}_t \cdot \tilde{\mathbf{C}}_t \quad (9)$$

输出门确定下一个隐藏状态的值:

$$\mathbf{o}_t = \sigma(\mathbf{W}_o \cdot [\mathbf{h}_{t-1}, x_t] + \mathbf{b}_o) \quad (10)$$

$$\mathbf{h}_t = \mathbf{o}_t \cdot \tanh(\mathbf{C}_t) \quad (11)$$

式中: $\tilde{\mathbf{C}}_t$ 为当前候选细胞状态; σ 为 sigmoid 函数; \tanh 为双曲正切函数; \mathbf{f}_t 、 \mathbf{i}_t 、 \mathbf{o}_t 分别为遗忘门、输入门、输出门在 t 时刻的计算结果; \mathbf{W}_f 、 \mathbf{W}_i 、 \mathbf{W}_c 、 \mathbf{W}_o 分别为各状态权重矩阵; \mathbf{b}_f 、 \mathbf{b}_i 、 \mathbf{b}_c 、 \mathbf{b}_o 分别为各状态的偏置矩阵。




图 3 LSTM 神经网络单元结构示意图

Fig.3 Schematic diagram of LSTM neural network unit structure

2.3 1DCNN&1DCNN-LSTM 组合神经网络模型

1DCNN&1DCNN-LSTM 模型结构如图 4 所示, 模型左侧为 2 层一维卷积层、1 层 Flatten 层和 2 层全连接层组成 (Dense 层); 右侧 1DCNN-LSTM 模型由 1 层一维卷积层、1 层 LSTM 神经网络和 1 层 Dense 层组成。将 1DCNN 和 1DCNN-LSTM 的输出结果汇入拼接层 (concatenate 层) 进行拼接操作后, 通过一层 Dense 进行结果输出, 优化器选用 Adam, 损失函数选用平均绝对误差 (MAE)。

左侧 1DCNN 模型用于提取多个临近电站数值天气预报水平辐照度, 进行空间相关性功率预测, 右侧 1DCNN-LSTM 模型中利用一维卷积神经网络对预测电站历史功率数据进行特征重构和提取高级信息, 增强对数据波动感知能力。并且利用 LSTM 神经网络对功率时序信息进行二次挖掘, 提取时间序列长期依赖特征, 进行时间序列预测。同时本文借鉴 Wide & Deep 模型对 Wide 和 Deep 2 部分进行联合训练的思想^[27], 将空间相关性功率预测结果与和时间序列预测结果进行拼接组合, 再通过全连接层进行学习, 分配权重, 完成对分布式光伏的超短期功率预测。

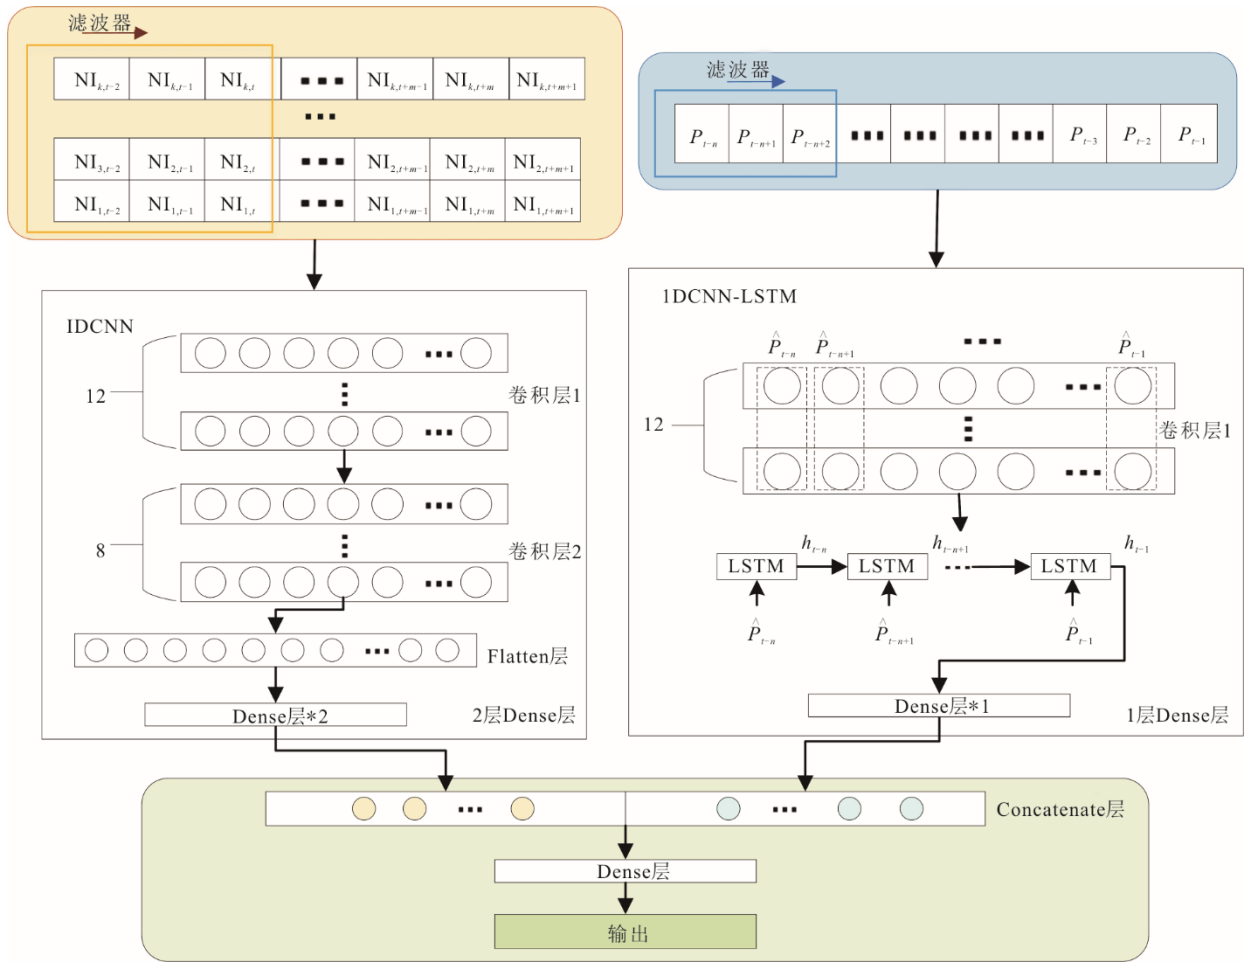


图 4 1DCNN & 1DCNN-LSTM 模型结构示意图
Fig.4 Structural diagram of 1DCNN& 1DCNN-LSTM model

3 分布式光伏超短期功率预测

3.1 功率预测流程

历史功率数据以及 NWP 预报数据对超短期预测精度有重要影响，为综合利用 NWP 预报信息与历史功率信息，提出了基于组合神经网络的分布式光伏超短期功率预测方法，其实现流程如图 5 所示。首先获取分布式电站周围多个临近集中式电站的 NWP 数据以及预测电站功率数据，将多个位置水平辐照度数据构成图 4 中矩阵形式（其中 $NI_{k,t}$ 表示第 K 个电站第 t 时刻的水平辐照度预报数据），水平辐照度输入长度根据预测时间尺度而定，预测功率时间为 $t \sim t+m-1$ 共 m 个时刻，同时考虑预测时刻临近时刻水平辐照度变化情况，再加入 $t-2$ 、 $t-1$ 、 $t+m$ 、 $t+m+1$ 时刻水平辐照度数据，共 $m+4$ 个时刻；前 n 个时刻功率时间序列为 $[P_{t-n}, P_{t-n+1}, \dots, P_{t-1}] \in \mathbb{R}^n$ ，数据经过一维卷积神经网络进行信息提取，重构样本空间特征，形成 d 维数组 $[\hat{P}_{t-n}; \hat{P}_{t-n+1}; \dots; \hat{P}_{t-1}] \in \mathbb{R}^{n \times d}$ 。

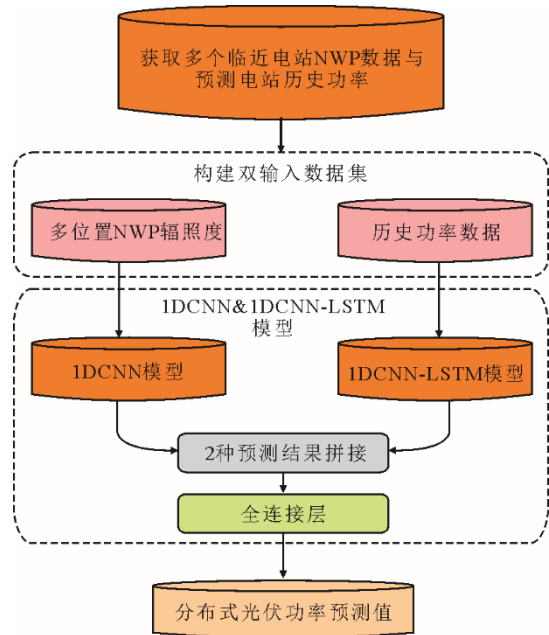


图 5 光伏功率预测流程
Fig.5 PV power prediction process

将多个位置 NWP 水平辐照度及预测电站历史功率数据进行归一化处理（式(12)）。

$$X_{\text{norm}} = \frac{X - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}} \quad (12)$$

将 2 种归一化数据输入预测模型中，将预测数据反归一化最终得到功率预测值。

3.2 误差分析

通过均方根误差 (root mean square error, RMSE) 和平均绝对误差 (mean absolute error, MAE) 对模型精度进行评估，计算公式为：

$$\delta_{\text{RMSE}} = \frac{\sqrt{\frac{1}{k} \sum_{i=1}^k (y_p^i - y^i)^2}}{y_{\text{max}}} \times 100\% \quad (13)$$

$$\delta_{\text{MAE}} = \frac{1}{k} \sum_{i=1}^k |y_p^i - y^i| \quad (14)$$

式中： k 为光伏功率待预测样本个数； y_p^i 为光伏功率预测结果； y^i 为光伏功率真实值； y_{max} 为光伏最大输出功率。

4 算例分析

分布式光伏电站无辐照度、温度等测量数据，利用 2 号光伏电站模拟分布式光伏电站，仅使用 2 号电站功率数据进行案例分析。

4.1 1DCNN&1DCNN-LSTM 模型参数

本文模型仿真所用平台参数：AMD Ryzen 7 5800H 3.20 GHz 处理器，编程语言 Python3.7，深度学习框架为 TensorFlow。表 2 为输出尺度为 8 点(未来 2 h 预测) 的神经网络结构参数。

表 2 神经网络结构参数
Tab.2 Neural network structure parameters

层 (类型)	输出形状	卷积核个数及尺寸	神经元数量	步长	连接上一层
Input_1(inputlayer)	(None,12,2)				
Input_2(inputlayer)	(None,48,1)				
Conv1d_L(conv1d)	(None,48,12)	12, 3		1	Input_2
Conv1d_1(conv1d)	(None,10,12)	12, 3		1	Input_1
Conv1d_2(conv1d)	(None,8,8)	8, 3		1	Conv1d_1
flatten(Flatten)	(None,64)				Conv1d_2
Lstm(LSTM)	(None,50)		50		Conv1d_L
Dense_1(Dense)	(None,20)		20		Flatten
Dense_2(Dense)	(None,8)		8		Dense_1
Dense_L(Dense)	(None,8)		8		Lstm
concatenate(Concatenate)	(None,16)				[Dense_L,Dense_2]
Dense_3(Dense)	(None,8)		8		concatenate

表 2 中 Input_1 输入为临近电站的 NWP 辐照度数据，Input_2 输入为历史功率数据，Conv1d_1 与 Conv1d_2 为图 4 中 1DCNN 模型所示的 2 个一维卷积层，Con1d_L 为 1DCNN-LSTM 模型的卷积层，为使序列长度不变，设置填充参数为“same”。Dense_1 和 Dense_2 为 1DCNN 模型 Dense 层，Dense_L 为 1DCNN-LSTM 的 Dense 层，2 个模型输出结果由 Concatenate 进行拼接，最后由 Dense_3 输出。神经网络模型结构参数参考文献[28-29]相关模型并加以调整，设定学习率为 0.000 3，批次 (Bstchsize) 为 32，损失函数值如图 6 所示。由图 6 可见，当训练次数为 10 时，损失函数值不再明显降低，训练次数为 25 之后变化极为缓慢。故训练次数 (epochs) 经多次测试设为 30。

4.2 实验结果分析

选取晴天 5 月 27—30 日以及非晴天 6 月 4—7 日

数据，以表格形式展示晴天与非晴天预测结果误差情况。为更清晰展示预测效果，晴天选取 5 月 30 日，非晴天选取 6 月 4 日和 6 月 6 日，以曲线形式展示预测结果。




图 6 损失函数变化曲线
Fig.6 Change curve of loss function

NWP 数据可以给出各变量未来某天的变化情

况, 预报信息每天更新 1 次, 直接给出水平辐照度预测值。可以通过 BP 神经网络训练和预测, 得出对应时刻功率预测, 同时也可以得到未来一天的功率预测结果, 对于各时间尺度下的超短期预测, 仅需对未来一天的预测结果进行不同尺度的“内采样”, 得到各尺度下的预测结果(进行 15 min 时间尺度预测, 直接获取对应 1 个时刻预测值; 进行 30 min 时间尺度预测, 直接获取对应 2 个时刻的预测值, 这样就可得到对应时间尺度的预测结果)。以临近电站 1 号和 3 号电站 NWP 数据对 2 号电站功率预测, 表 3 为晴天与非晴天 NWP 预测误差。图 7—图 8 分别展示了晴天与非晴天临近电站 NWP 预测结果。

表 3 晴天与非晴天 NWP 预测误差
Tab.3 NWP prediction error in sunny and non-sunny days

天气类型	临近电站	$\delta_{RMSE}/\%$	δ_{MAE}
晴天	1 号	6.673	0.678
	3 号	8.571	0.916
非晴天	1 号	13.601	1.258
	3 号	14.639	1.302




图 7 晴天临近电站 NWP 预测结果
Fig.7 Results of sunny weather prediction using NWP of nearby power stations




图 8 非晴天临近电站 NWP 预测结果
Fig.8 Results of non-sunny weather prediction using NWP from nearby power stations

由表 3 以及图 7—图 8 可以看出, 仅使用 NWP 数据进行预测会有较大误差, 时间序列方法在超短

期预测具有良好的预测效果, 但随预测尺度的增加, 精度会迅速下降。分布式光伏超短期预测需要结合时间序列预测与临近电站 NWP 预测方法, 来提高各尺度下超短期预测精度。

表 4 为不同时间尺度不同模型晴天预测误差, 图 9—图 11 分别给出时间尺度为 15 min、1.0 h、2.0 h 不同模型晴天预测结果, 图 12—图 14 分别给出时间尺度为 15 min、1.0 h、2.0 h 不同模型非晴天预测结果, 表 5 为不同时间尺度不同模型非晴天预测误差。

表 4 不同时间尺度不同模型晴天预测误差
Tab.4 Forecast error of different time scales and models in sunny days

模型方法	误差	15 min	30 min	1.0 h	1.5 h	2.0 h
C&CL-1	$\delta_{RMSE}/\%$	4.087	4.185	4.499	4.827	5.150
	δ_{MAE}	0.349	0.366	0.413	0.449	0.485
C&CL-3	$\delta_{RMSE}/\%$	4.131	4.246	4.547	4.863	5.222
	δ_{MAE}	0.350	0.374	0.422	0.456	0.496
C&CL-13	$\delta_{RMSE}/\%$	4.057	4.162	4.457	4.705	4.965
	δ_{MAE}	0.338	0.362	0.410	0.439	0.466
CL	$\delta_{RMSE}/\%$	4.187	4.435	5.016	5.734	6.570
	δ_{MAE}	0.361	0.395	0.478	0.555	0.638
LSTM	$\delta_{RMSE}/\%$	4.305	4.458	5.250	6.047	7.138
	δ_{MAE}	0.423	0.453	0.525	0.596	0.698




图 9 时间尺度为 15 min 不同模型晴天预测结果
Fig.9 Forecast results of different models with a time scale of 15 minutes in sunny days




图 10 时间尺度为 1.0 h 不同模型晴天预测结果
Fig.10 Forecast results of different models with a time scale of 1.0 h in sunny days

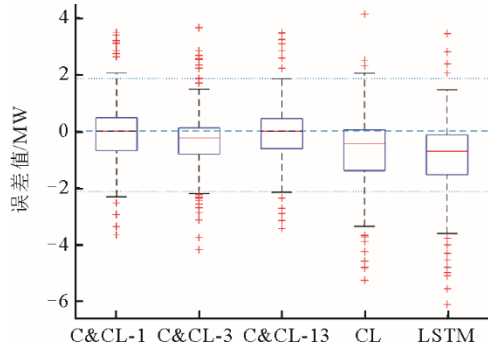


图 11 时间尺度为 2.0 h 不同模型晴天预测误差

Fig.11 Error results of different models with a time scale of 2.0 h in sunny days

表 5 不同时间尺度不同模型非晴天预测误差

Tab.5 Forecast error of different time scales and models in non-sunny days

模型方法	误差	15 min	30 min	1.0 h	1.5 h	2.0 h
C&CL-1	$\delta_{RMSE}/\%$	5.535	6.460	8.147	9.258	10.374
	δ_{MAE}	0.465	0.573	0.731	0.845	0.941
C&CL-3	$\delta_{RMSE}/\%$	5.552	6.787	8.254	9.590	10.616
	δ_{MAE}	0.477	0.610	0.772	0.884	0.978
C&CL-13	$\delta_{RMSE}/\%$	5.546	6.538	8.156	9.032	9.893
	δ_{MAE}	0.471	0.564	0.705	0.805	0.890
CL	$\delta_{RMSE}/\%$	5.454	6.815	8.653	10.177	11.413
	δ_{MAE}	0.466	0.603	0.772	0.910	1.026
LSTM	$\delta_{RMSE}/\%$	6.526	7.454	9.140	10.732	12.217
	δ_{MAE}	0.596	0.683	0.841	0.991	1.135

表 4、表 5 和图 9—图 14 中 C&CL 表示




图 12 时间尺度为 15 min 各模型非晴天预测结果

Fig.12 Forecast results of all models with a time scale of 15 min in non-sunny days




图 13 时间尺度为 1.0 h 各模型非晴天预测结果

Fig.13 Forecast results of all models with a time scale of 1.0 h in non-sunny days

1DCNN& 1DCNN-LSTM 模型, CL 表示 1DCNN-LSTM 模型, 1DCNN-LSTM 与 LSTM 仅做时间序列预测, 数字表示输入选取的临近电站编号, 如 C&CL-13 表示 1DCNN&1DCNN-LSTM 模型的 1DCNN 部分输入 1 号电站与 3 号电站 NWP 水平辐照度信息。

综合表 4、表 5、图 9—图 14 可以看出:

1) 不论是晴天还是非晴天, 在相同的学习率、批次数以及训练次数下, 1DCNN-LSTM 模型在各时间尺度上对于时间序列的预测结果要优于 LSTM。同时在 15 min 的时间尺度上, 对于晴天, 添加临近电站辐照度预报信息的 1DCNN& 1DCNN-LSTM 模型预测精度略高于 1DCNN-LSTM 模型; 对于非晴天, 添加临近电站辐照度预报信息的 1DCNN&1DCNN-LSTM 模型预测的均方根误差略大于 1DCNN-LSTM 模型。在 30 min 的时间尺度上, 加入辐照度预报信息的 1DCNN&1DCNN-LSTM 模型的均方根误差略低于 1DCNN-LSTM 模型。

2) 在 1.0~2.0 h 的时间尺度上的晴天预测, 结合辐照度预报数据的 1DCNN&1DCNN-LSTM 模型的预测效果要明显优于 1DCNN-LSTM 模型; 因晴天功率数据波动较小, 结合多位置辐照度的 1DCNN&1DCNN-LSTM 模型预测结果略微优于单位置预测结果。

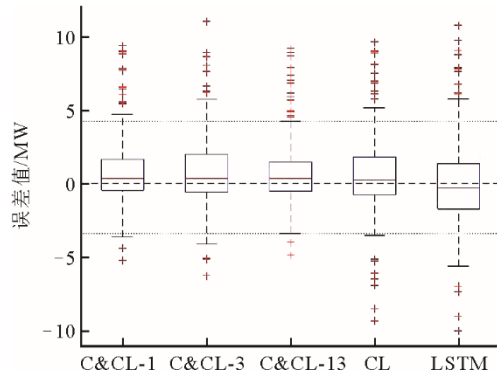


图 14 时间尺度为 2.0 h 各模型非晴天预测误差
Fig.14 Error results of all models with a time scale of 2.0 h in non-sunny days

3) 在 1.0~2.0 h 的时间尺度上的非晴天预测, 结合辐照度的 1DCNN&1DCNN-LSTM 模型的预测效果要优于 1DCNN-LSTM 模型, 在 1.5~2.0 h 的时间尺度上, 多位置水平辐照度的预测误差要小于单位置水平辐照度的预测误差。

5 结 论

为充分利用 NWP 包含的辐照度预报信息与历史功率信息, 进一步提高分布式光伏功率超短期预测的准确率, 本文提出了一种基于组合神经网络的分布式光伏功率超短期预测方法, 通过算例分析得到以下结论:

1) 对于时间序列预测, 1DCNN-LSTM 模型能够利用 1DCNN 的一维卷积层对数据进行空间重构, 增强了对数据波动感知能力, 结合 LSTM 神经网络提取数据的长期依赖特征, 实现对历史功率的挖掘, 充分学习时间序列变化规律挖掘功率时间序列里的隐藏信息, 相比于 LSTM 模型, 提高了预测精度。

2) 基于电站间的空间相关性, 分布式光伏周围多个位置临近电站辐照度预报数据包含更多信息, 在较长预测尺度上, 考虑了多个位置水平辐照度预报数据的模型预测结果比只考虑单位置的模型预测误差更低。

3) 从整体角度来看, 本文提出的基于组合神经网络的分布式光伏功率超短期预测方法保持了各时间尺度下较低的预测误差。

【参 考 文 献】

[1] 谭显东, 刘俊, 徐志成, 等. “双碳”目标下“十四五”电力供需形势[J]. 中国电力, 2021, 54(5): 1-6.
TAN Xiandong, LIU Jun, XU Zhicheng, et al. Power supply and demand balance during the 14th five-year plan

period under the goal of carbon emission peak and carbon neutrality[J]. Electric Power, 2021, 54(5): 1-6.

[2] 国家能源局. 2021 年光伏发电建设运行情况[EB/OL]. (2022-03-09) [2022-06-30]. http://www.nea.gov.cn/2022-03/09/c_1310508114.htm.
National Energy Administration. Construction and operation of photovoltaic power generation in 2021 [EB/OL]. (2022-03-09) [2022-06-30]. http://www.nea.gov.cn/2022-03/09/c_1310508114.htm.

[3] 乔颖, 孙荣富, 丁然, 等. 基于数据增强的分布式光伏电站群短期功率预测(一): 方法框架与数据增强[J]. 电网技术, 2021, 45(5): 1799-1808.
QIAO Ying, SUN Rongfu, DING Ran, et al. Distributed photovoltaic station cluster gridding short-term power forecasting part I: methodology and data augmentation[J]. Power System Technology, 2021, 45(5): 1799-1808.

[4] 王彪, 吕洋, 陈中, 等. 考虑信息时移的分布式光伏机理-数据混合驱动短期功率预测[J]. 电力系统自动化, 2022, 46(11): 67-74.
WANG Biao, LYU Yang, CHEN Zhong, et al. Hybrid mechanism-data-driven short-term power forecasting of distributed photovoltaic considering information time shift[J]. Automation of Electric Power Systems, 2022, 46(11): 67-74.

[5] 马原, 张雪敏, 甄钊, 等. 基于修正晴空模型的超短期光伏功率预测方法[J]. 电力系统自动化, 2021, 45(11): 44-51.
MA Yuan, ZHANG Xuemin, ZHEN Zhao, et al. Ultra-short-term photovoltaic power prediction method based on modified clear-sky model[J]. Automation of Electric Power Systems, 2021, 45(11): 44-51.

[6] 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.
LAI Changwei, LI Jinghua, CHEN Bo, et al. Review of photovoltaic power output prediction technology[J]. Transactions of China Electrotechnical Society, 2019, 34(6): 1201-1217.

[7] 黄磊, 舒杰, 姜桂秀, 等. 基于多维时间序列局部支持向量回归的微网光伏发电预测[J]. 电力系统自动化, 2014, 38(5): 19-24.
HUANG Lei, SHU Jie, JIANG Guixiu, et al. Photovoltaic generation forecast based on multidimensional time-series and local support vector regression in microgrids[J]. Automation of Electric Power Systems, 2014, 38(5): 19-24.

[8] KAREVAN Z, SUYKENS J A K. Transductive LSTM for time-series prediction: an application to weather forecasting[J]. Neural Networks, 2020, 125: 1-9.

[9] 王晶, 黄越辉, 李驰, 等. 考虑空间相关性和天气类型划分的多光伏电站时间序列建模方法[J]. 电网技术, 2020, 44(4): 1376-1384.
WANG Jing, HUANG Yuehui, LI Chi, et al. Time series modeling method for multi-photovoltaic power stations considering spatial correlation and weather type classification[J]. Power System Technology, 2020, 44(4): 1376-1384.

[10] CHEN H L, CHANG X F. Photovoltaic power prediction of LSTM model based on Pearson feature selection[J]. Energy Reports, 2021, 7: 1047-1054.

[11] 王超洋, 张蓝宇, 刘铮, 等. 基于特征挖掘的 indRNN 光伏发电功率预测[J]. 电力系统及其自动化学报, 2021, 33(4): 17-22.
WANG Chaoyang, ZHANG Lanyu, LIU Zheng, et al. Feature mining based indRNN photovoltaic power

- generation prediction[J]. Proceedings of the CSU-EPSSA, 2021, 33(4): 17-22.
- [12] 刘国海, 孙文卿, 吴振飞, 等. 基于 Attention-GRU 的短期光伏发电功率预测[J]. 太阳能学报, 2022, 43(2): 226-232.
LIU Guohai, SUN Wenqing, WU Zhenfei, et al. Short-term photovoltaic power forecasting based on Attention-GRU model[J]. Acta Energetica Solaris Sinica, 2022, 43(2): 226-232.
- [13] MA X Y, ZHANG X H. A short-term prediction model to forecast power of photovoltaic based on MFA-Elman[J]. Energy Reports, 2022, 8: 495-507.
- [14] 谭小钰, 刘芳, 马俊杰, 等. 基于 DBN 与 T-S 时变权重组合的光伏功率超短期预测模型[J]. 太阳能学报, 2021, 42(10): 42-48.
TAN Xiaoyu, LIU Fang, MA Junjie, et al. Ultra-short-term PV power forecasting model based on DBN and T-S time-varying weight combination[J]. Acta Energetica Solaris Sinica, 2021, 42(10): 42-48.
- [15] HU K Y, CAO S H, WANG L D, et al. A new ultra-short-term photovoltaic power prediction model based on ground-based cloud images[J]. Journal of Cleaner Production, 2018, 200: 731-745.
- [16] 刘晓艳, 王珏, 姚铁锤, 等. 基于卫星遥感的超短期分布式光伏功率预测[J]. 电工技术学报, 2022, 37(7): 1800-1809.
LIU Xiaoyan, WANG Jue, YAO Tiechui, et al. Ultra short-term distributed photovoltaic power prediction based on satellite remote sensing[J]. Transactions of China Electrotechnical Society, 2022, 37(7): 1800-1809.
- [17] 程礼临, 臧海祥, 卫志农, 等. 考虑多光谱卫星遥感的区域级超短期光伏功率预测[J]. 中国电机工程学报, 2022, 42(20): 7451-7465.
CHENG Lilin, ZANG Haixiang, WEI Zhinong, et al. Ultra-short-term forecasting of regional photovoltaic power generation considering multispectral satellite remote sensing data[J]. Proceedings of the CSEE, 2022, 42(20): 7451-7465.
- [18] 王晨阳, 段倩倩, 周凯, 等. 基于遗传算法优化卷积长短记忆混合神经网络模型的光伏发电功率预测[J]. 物理学报, 2020, 69(10): 149-155.
WANG Chenyang, DUAN Qianqian, ZHOU Kai, et al. A hybrid model for photovoltaic power prediction of both convolutional and long short-term memory neural networks optimized by genetic algorithm[J]. Acta Physica Sinica, 2020, 69(10): 149-155.
- [19] 张雲钦, 程起泽, 蒋文杰, 等. 基于 EMD-PCA-LSTM 的光伏功率预测模型[J]. 太阳能学报, 2021, 42(9): 62-69.
ZHANG Yunqin, CHEN Qize, JIANG Wenjie, et al. Photovoltaic power prediction model based on EMD-PCA-LSTM[J]. Acta Energetica Solaris Sinica, 2021, 42(9): 62-69.
- [20] 潘超, 李润宇, 王典, 等. 基于风速时空关联的多步预测方法[J]. 太阳能学报, 2022, 43(2): 458-464.
PAN Chao, LI Runyu, WANG Dian, et al. Multi-step wind speed prediction method based on wind speed spatial-time correlation[J]. Acta Energetica Solaris Sinica, 2022, 43(2): 458-464.
- [21] 黄发明, 汪洋, 董志良, 等. 基于灰色关联度模型的区域滑坡敏感性评价[J]. 地球科学, 2019, 44(2): 664-676.
HUANG Faming, WANG Yang, DONG Zhiliang, et al. Regional landslide susceptibility mapping based on grey relational degree model[J]. Earth Science, 2019, 44(2): 664-676.
- [22] 周正峰, 于晓涛, 陶雅乐, 等. 基于灰色关联分析的树脂与弹性体高黏沥青高温性能评价[J/OL]. 吉林大学学报(工学版): 1-13[2022-07-26].
ZHOU Zhengfeng, YU Xiaotao, TAO Yale, et al. High-temperature performance evaluation of resin and elastomer high viscosity asphalt based on grey correlation analysis[J]. Journal of Jilin University (Engineering and Technology Edition): 1-13[2022-07-26].
- [23] YAO T C, WANG J, WU H Y, et al. A photovoltaic power output dataset: Multi-source photovoltaic power output dataset with Python toolkit[J]. Solar Energy, 2021, 230: 122-130.
- [24] 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.
MENG Anbo, CHEN Jiaming, LI Zhanlian, et al. Short-term photovoltaic power generation prediction based on similar day theory and CSO-WGPR[J]. High Voltage Engineering, 2021, 47(4): 1176-1184.
- [25] 赵恺, 石立宝. 基于改进一维卷积神经网络的电力系统暂态稳定评估[J]. 电网技术, 2021, 45(8): 2945-2957.
ZHAO Kai, SHI Libao. Transient stability assessment of power system based on improved one-dimensional convolutional neural network[J]. Power System Technology, 2021, 45(8): 2945-2957.
- [26] GREFF K, SRIVASTAVAR K, KOUTNIK J, et al. LSTM: A search space odyssey[J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(10): 2222-2232.
- [27] DA F, PENG C, WANG H M, et al. A risk detection framework of Chinese high-tech firms using wide & deep learning model based on text disclosure[J]. Procedia Computer Science, 2022, 199: 262-268.
- [28] 向玲, 刘佳宁, 苏浩, 等. 基于 CEEMDAN 二次分解和 LSTM 的风速多步预测研究[J]. 太阳能学报, 2022, 43(8): 334-339.
XIANG Ling, LIU Jianing, SU Hao, et al. Research on multi-step wind speed forecast based on CEEMDAN secondary decomposition and LSTM[J]. Acta Energetica Solaris Sinica, 2022, 43(8): 334-339.
- [29] 尹梓诺, 马海龙, 胡涛. 基于联合注意力机制和 1 维卷积神经网络-双向长短期记忆网络模型的流量异常检测方法[J/OL]. 电子与信息学报: 1-10 [2023-05-16]. <http://kns.cnki.net/kcms/detail/11.4494.tn.20220913.1115.030.html>.
YIN Zinuo, MA Hailong, HU Tao. A traffic anomaly detection method based on the joint model of attention mechanism and one-dimensional convolutional neural network-bidirectional long short term memory[J/OL]. Journal of Electronics & Information Technology: 1-10[2023-05-16]. <http://kns.cnki.net/kcms/detail/11.4494.tn.20220913.1115.030.html>.

(责任编辑 杜亚勤)