新能源技术+

文章编号-1001-2060(2024)05-0143-07

程

基于随机森林和支持向量回归的风力发电预测算法

彭嘉宁,徐鹤勇

(国网宁夏电力有限公司 宁夏电力调度控制中心,宁夏 银川 750001)

要:为实现精确的风能出力预测,保障风力发电系统稳定并网,提出了一种基于随机森林模型和支持向量回归 摘 模型的精确风力发电功率预测算法。该算法以回归树和随机森林模型为基础,对风力发电影响因素进行特征重要 性评估:基于特征筛选理论.构建最优特征集合:使用最优特征集合输入支持向量回归模型.实现风力发电功率的 预测。为验证算法的有效性,使用实测数据开展实验分析。实验结果表明:相比于单独使用随机森林模型,本文算 法大幅提高了预测精度,平均绝对误差降低了19.67%;相比于长短时神经网络模型,本文算法在保持同样高精度 的同时,大幅降低了模型复杂度以及所需的训练时间。本文算法能够实现风力发电功率精确预测,具有较为重要 的理论和实际意义。

键 词:风力发电;功率预测;支持向量回归;随机森林模型 关

中图分类号:TP391 文献标识码:A DOI:10.16146/j. cnki. rndlgc. 2024.05.016

[引用本文格式] 彭嘉宁, 徐鹤勇. 基于随机森林和支持向量回归的风力发电预测算法[J]. 热能动力工程, 2024, 39(5): 143-149. PENG Jianing, XU Heyong. Wind power prediction algorithm based on random forest and support vector regression [J]. Journal of Engineering for Thermal Energy and Power, 2024, 39(5):143-149.

Wind Power Prediction Algorithm based on Random Forest and **Support Vector Regression**

PENG Jianing, XU Heyong

(Ningxia Power Dispatching Control Center of State Grid Ningxia Electric Power Co., Ltd., Yinchuan, China, Post Code: 750001)

Abstract: To achieve accurate wind power output prediction and ensure the stable grid connection of wind power generation systems, an accurate wind power prediction algorithm based on the random forest model and support vector regression model was proposed. The algorithm was based on regression trees and random forest models to evaluate the importance of factors affecting wind power generation; based on feature selection theory, an optimal feature set was constructed; the optimal feature set was input into the support vector regression model to predict wind power generation. In order to verify the validity of the algorithm, this paper used actually measured data to carry out experimental analysis. Experimental results show that compared to using the random forest model alone, the algorithm significantly improves the prediction accuracy with a reduction of 19.67% in average absolute error; compared to the long short-term memory neural network model, the algorithm achieves the same high accuracy while significantly reducing the model complexity and training time required. The algorithm can achieve accurate wind power prediction, which has important theoretical and practical significance.

收稿日期:2023-10-20: 修订日期:2023-11-30

基金项目:国家电网科技项目(2017NR58337)

Fund-supported Project: State Grid Technology Project (2017NR58337)

作者简介:彭嘉宁(1981-),男,国网宁夏电力有限公司高级工程师.

Key words: wind power generation, power prediction, support vector regression, random forest model

引 言

风力发电已成为世界各国发展可再生能源的重 要途径之一^[1]。风电输出功率的精确预测是风电 安全并网的前提,也是实现电网系统稳定运行和高 质量调度的重要保障^[2-3]。然而,由于风力发电系 统受环境因素影响很大,风电功率的精确预测较为 困难。

现阶段针对风力发电功率预测常用的方法主要 可以分为物理建模、统计分析、机器学习和混合算法 4个主要方向^[4,5]。物理方法主要基于真实环境的 物理建模分析,如文献[6-7]基于环境天气预报和 风力发电系统参数建立预测模型,可以在环境状态 稳定的情况下计算高可靠性的发电功率。但是这类 方法对模型精度和参数测量精度要求过高,模型难 以迁移和实现工程化,因此实际应用情况下受限制 较多。典型的统计方法有两种,分别是基于自回归 积分移动平均法以及基于马尔可夫链的预测方法。 文献[8-9]采用这类方法能够给出长期的预测结 果,但是由于难以捕捉非线性特征,预测精度较差。 采用长短时记忆神经网络模型(LSTM)的机器学习 方法进行短期风力发电预测是近些年的研究热点, 学者们使用 LSTM 网络针对风力发电功率预测算法 进行适应性改进,获得了较高的预测精度^[10]。虽然 神经网络具有较强的非线性建模能力和适应性,但 其需要大量数据和较长的训练时间,同时容易产生 过拟合问题。为了提高预测精度,可以采用整合以 上各类算法的混合模型,该类方法是当前的研究热 点^[11],如姚越等人^[12]提出的基于注意力机制的卷 积神经网络-长短期记忆网络模型,实现了较为精 确的功率预测。但是该方法模型复杂,对数据集较 为敏感,训练和预测难度较大。

本文采用随机森林 - 支持向量回归算法 (RF-SVR)进行风力发电功率预测。该算法结合了 随机森林(RF)和支持向量回归算法(SVR)的优势, 能够充分挖掘高维数据特征,减少维数灾难问题,在 保证预测精度的前提下降低了参与计算的数据量, 可为风力发电系统的运行和管理提供更好的支持和 保障。

1 风力发电功率预测算法

1.1 基于 RF 的特征重要性评估模型

现代风力发电厂通常配备环境监测系统,能够 提供包括风速、风向、温度、湿度和气压等多种环境 参考数据。风力发电系统则可以通过大量的测量传 感器提供涡轮机转子温度、速度、偏航角、桨距角、转 子转矩和叶片大小等测量参数数据。理论上考虑更 多的参数可以获得更为精确的预测结果,但是不同 因素对预测结果影响的权重并不一致,过多的影响 因素会导致模型产生维度灾难问题。此外,各类传 感器提供的测量结果会存在随机误差,随机误差的 累积也会进一步影响预测精度。

为解决这一问题,本文通过随机森林模型实现 风力发电功率预测中相关影响因素的特征重要性筛 选,基于特征重要性评估对特征数据进行降维操作。 为实现所述过程,以二叉树结构的回归决策树为基 础构建随机森林模型,回归决策树中每个内部节点 对应于一个特征属性的判断条件,每个分支表示该 判断条件的一个输出结果,而每个叶节点则存储一 个连续值作为预测结果。

对于二叉决策树来说,其切分点直接影响模型的最终效果。考虑到风力发电功率预测属于回归问题,基于平方误差(MSE)选择最优切分变量,最优切分点的计算公式如式(1)所示,式中 y_i 指该点的 真实值。

$$\min_{i,m} \left[\min_{c_1} \sum_{x_i \in R_1(i,m)} (y_i - c_1)^2 + \min_{c_2} \sum_{x_i \in R_2(i,m)} (y_i - c_2)^2 \right]$$
(1)

式中:i—第i个变量;m—第m个划分点; $R_1(i,m)$ — 划分后的左半区域; $R_2(i,m)$ —划分后的右半区域; c_1, c_2 —区域 $R_1(i,m)$ 和 $R_2(i,m)$ 的最优输出值。

以最优切分变量为基础,通过设置合适的节点 深度阈值,递归构建决策树。树的深度与预测效果 并非线性相关,深度过度的决策树容易出现过拟合 问题。针对风力发电影响参数过多,数据集和对应 模型泛用性较差的问题,本文以代价复杂度后剪枝 的方式对递归构建的决策树进行剪枝,降低过拟合 的风险。代价复杂度损失函数为:

$$R_{\alpha}(t) = R_{e}(t) + \alpha \mid t \mid$$
(2)

式中:*t*—任意子树; |*t*|—叶节点个数; *R_e*(*t*)—预测 误差; α—待定系数, 用于平衡拟合程度和树的复杂 度, 引导模型使用更少的叶节点。

以完整的决策树为基础,采用自底向上的序贯 剪枝策略获得子树序列 $T_0, T_1 \cdots T_n$,其中 T_0 为完整 的决策树, T_n 为单独的根节点。为获得最优的 α 值 与其对应的最优子树 $T(\alpha)$,构建参数 l 辅助序贯剪 枝,其计算式为:

$$l = \frac{R(t) - R(t_{\rm p})}{|T_t| - 1}$$
(3)

式中:R(t)—节点 t 的代价复杂度; $R(t_p)$ —节点 t父节点的代价复杂度; $|T_t|$ —节点 t 子树包含的叶 节点个数。

通过寻找节点 t 使得辅助参数 l 最小,即可认为 该节点为临界点。剪出该节点以下的叶节点,在这 个新的树中再重新寻找新的最小化 l_{\circ} 由此可以得 到与子树序列 $T_0, T_1 \cdots T_n$ 对应的 α 值序列 $\alpha_0, \alpha_1 \cdots$ α_n ,通过交叉验证,即可获得最终的剪枝结果,即在 式(2)损失函数条件下的最优子树 $T(\alpha)_{\circ}$

通过对每棵决策树进行上述操作后构建随机森 林模型。在构建随机森林时,每棵决策树的生成过 程是独立的,即每棵树都采用上述过程进行构建,但 是每棵树的选取特征和切分点不同,从而增加模型 的多样性。为实现最终的特征重要性分析,以随机 森林模型为基础,利用袋外数据(OOB)进行特征重 要性排序。袋外数据是指针对某棵决策树,未被选 择作为训练集的数据。下面以单一特征 J 为例说明 特征重要性排序步骤:

(1)用每棵决策树对应的袋外数据计算各自的 袋外数据误差 OOB1ⁱ_a,(*i*=1,2,…,*n*);

(2)针对某一特征 J,对其特征数据添加随机
 噪声,重新计算袋外误差 OOB2ⁱ_a,(i=1,2,...,n);

(3) 通过 OOB 错误率变化情况计算特征 J 的 重要性增益 IG,其数值越大表明该特征与预测结果 更为相关,即影响权重更大,其计算公式为:

$$IG_J = \frac{1}{n} \sum_{i=1}^{n} OBB1_e^i - OBB2_e^i$$
(4)

式中:n一样本数量。

通过对全部特征重复上述步骤并计算重要性 增益 IG,最终得到平均特征重要性排名。综上所 述,本文所建立的随机森林模型的整体架构如图 1 所示。





Fig. 1 Feature importance assessment model architecture

1.2 特征筛选优化模型

本文采用 SVR 模型实现最终的功率预测,在预测功率前需进行特征数据筛选及优化。为实现在控制输入 SVR 模型特征数量的同时保证模型的精度, 从最重要的特征开始,逐渐增加选取的特征数量,构 建多个特征子集并评估 RF-SVR 模型。在每次迭代 中,选择平均绝对误差作为统一的性能评价指标,通 过多次迭代获得最优的特征数量。即在保留尽量少 特征的同时,仍能获得较好的模型性能。以特征筛 选优化模型为基础,降低 RF-SVR 模型的复杂度,从 而得到一个更稳定且泛化能力更强的预测模型。优 化模型为:

$$X^* = \operatorname{argmin} X_k L(f(X_k, \theta_k))$$
(5)

式中: X^* —选定的最优特征子集; X_k —选取的包含 k个特征的特征子集;L—损失函数,用于评估模型 f在特征子集 X_k 和参数 θ_k 下的性能。

1.3 基于 SVR 的功率预测模型

为解决非线性的风力发电功率预测问题,本文 基于支持向量回归理论,在特征空间中构建最优超 平面实现回归预测。超平面是一个由权重向量和偏 差值确定的线性决策边界,在面向回归分析问题求 解时,可以用于预测连续变量的输出。本文提出的 算法通过设置合理的容忍误差 *ξ*,使 SVR 模型支持 一定范围内的预测误差,预测结果在容忍间隔带内 即视为正确预测,实现间隔最大化的约束条件下的 预测误差最小化,从而更好地适应风力发电的不稳 定特征。

为求解该超平面,设计优化模型为:

$$\begin{cases} \min_{w,b,\xi,\xi^{*}} \frac{1}{2} \| \boldsymbol{w} \|^{2} + C \sum_{i=1}^{n} (\xi_{i} + \xi_{i}^{*}) \\ y_{i} - \langle \boldsymbol{w}, \boldsymbol{\phi}(x_{i}) \rangle - b \leq \delta + \xi_{i}, \\ \langle w, \boldsymbol{\phi}(x_{i}) \rangle - b - y_{i} \leq \delta + \xi_{i}^{*}, \\ \xi_{i}, \xi_{i}^{*} \geq 0, i = 1, \cdots, n \end{cases}$$
(6)

式中:w—权重向量;b—偏差值; ξ 和 ξ^* —容忍误 差;C—惩罚系数; $\phi(x_i)$ —核函数; δ —容忍度;n— 样本数量; ξ_i 和 ξ_i^* —对应于样本 x_i 的上下间隔 误差。

通过固定计算公式将输入数据映射到高维特征 空间,公式的设计方式和计算效果是影响 SVR 模型 预测效果的关键因素之一。考虑到风力发电预测问 题背景下的强烈非线性特征,本文采用径向基核函 数(RBF)来实现低维数据到高维空间的映射,如式 (7)所示:

$$K(x_{i}, x_{i}) = e^{-\gamma \|x_{i} - x_{j}\|^{2}}$$
(7)

式中: $\|x_i - x_j\|^2$ —欧几里得距离的平方; γ —高斯 核函数的带宽参数, 通过修改高斯函数的幅值和范 围, 可以控制数据在高维特征空间中的分布情况, 进 而保证模型在局部最优的情况下避免过拟合。

通过这一模型,可以将优化问题转化为对偶问 题,使用支持向量回归算法求解得到一组最优解 w^{*},b^{*},ξ^{*}和ξ_i^{*}。其中,w^{*}是求解得到的最优权重 向量,b^{*}是求解得到的最优偏差值,如图2所示。 根据核函数和模型获得的最优参数,构建超平面并 进行预测,超平面的公式可表示为:



Fig. 2 Support vector regression model

2 功率预测流程

RF-SVR 算法整体流程如图 3 所示。可以将算 法分为两部分:第一部分为特征筛选和模型训练,利 用待测风力发电系统的历史真实数据构建训练集, 进行异常值剔除和数据标准化等数据清洗工作后, 通过随机森林模型获得特征重要性排序,并通过特 征筛选优化模型构建最优特征子集,使用最优特征 数据训练支持向量回归模型;第二部分为实际预测 阶段,在此阶段将筛选后的特征输入 SVR 模型,获 得最终的预测结果。



图 3 RF-SVR 算法整体流程 Fig. 3 Overall algorithm workflow of RF-SVR

3 实验结果与分析

3.1 实验数据分析

为验证 RF-SVR 算法的有效性,本文以宁夏某 风力发电厂 2021 年的实测数据为基础开展了实验 研究,并基于传感器和环境监测系统的历史数据记 录构建了数据集。数据集主要包括风速、风向、环境 温度、电机转子温度、转向器角度、叶轮叶片桨距角 等 16 种实测参数,如表 1 所示。实验目标变量为发 电系统实际输出功率。

表1 数据集参数标签 Tab.1 Dataset parameter labels

序号	影响因素	序号	影响因素
1	风速	9	转向器角度
2	风向	10	叶片长度
3	转子速度	11	轮毂高度
4	涡轮机高度	12	安装角1
5	空气密度	13	安装角2
6	桨距角1	14	安装角3
7	桨距角2	15	环境温度
8	桨距角3	16	环境湿度

3.2 特征筛选实验

采用随机森林模型对数据集进行了特征筛选, 特征重要性排名如图4所示。图中数值为归一化后 的特征重要性评分占比,对应单一特征在整体重要 性评分中所占权重。



图 4 特征重要性权重分布

Fig. 4 Feature importance weight distribution

以重要性排名为基础,使用本文所提出的特征 筛选算法得到最优特征集合为{风速、桨距角3、桨 距角1、桨距角2、转向器角度、环境温度}。显然,风 速是影响风力发电系统最主要的特征因素,其特征 相对重要性得分为6.49,重要性占比高达0.46;与 之相比风向的影响权重则较低,特征重要性得分仅 为0.71,重要性占比为0.05。这一结论仅适用于本 数据集而无法推广至其他风力发电系统,这是由于 本数据集中提供了发电系统叶轮叶片的桨距角、安 装角以及转向器角度等实测参数,由此削弱了风向 特征的影响权重。这从另一角度证实了特征重要性 分析和特征筛选的重要性。通过特征筛选,能够剔 除影响不大的特征因素,避免因长时间测量误差累 积对模型训练造成的影响以及过拟合的风险。

此外,特征筛选算法的另一优势是大幅降低了 预测训练速度和预测所需的系统算力及内存。在本 文实验中,后续预测模型所使用的数据种类为6种, 相比于原始数据的16种缩减了62.5%,这为算法 实现工程化提供了必要条件。

本文对算法处理时间进行了分析,实验中使用 的计算平台 CPU 型号为 I7-12700, GPU 型号为 GTX3080,内存为 32 G。表 2 为4 种算法在处理时 间方面的对比。通过表中数据可以发现,4 种算法 中,LSTM 所需的训练时间最长,模型训练时间为 4 526.13 s,RF-SVR 算法训练时间为 392.74 s。另 外,相比于 RF、SVR 和 LSTM, RF-SVR 算法大幅降 低了预测阶段所占用的内存,计算速度分别提高了 55%,18%和10%。这意味着通过 RF-SVR 的集成 学习框架, RF-SVR 算法可以实现基于实时测量数 据的优化设计,进而实现超短时的风力发电功率 预测。

表 2 计算速度与内存占用情况 Tab. 2 Calculation speed and memory usage

模型	训练时间/s	计算速度/s	占用内存/MB
RF	321.26	0.20	44.71
SVR	494.17	0.11	6.57
LSTM	4 526.13	0.10	45.30
RF-SVR	392.74	0.09	3.60

3.3 验证集测试结果

使用验证集对模型预测效果进行分析。实验中

单独使用随机森林模型、支持向量回归模型、LSTM、 以及 RF-SVM 对数据进行了预测。选择决定系数 *R*²、平均绝对误差(MAE)、均方根误差(RMSE)作为 预测精度的评价指标。其中决定系数可以反映回归 模型的拟合效果,决定系数越接近1,表示模型的拟 合效果越好,预测值与真实值的相关性越强。MAE 和 RMSE 可以直观反映模型整体预测误差的大小。 指标的具体计算公式如下:

$$R^{2} = 1 - \frac{\sum_{i=1}^{n} (y_{i} - \hat{y}_{i})^{2}}{\sum_{i=1}^{n} (y_{i} - \bar{y})^{2}}$$
(9)

MAE =
$$\frac{1}{n} \sum_{i=1}^{n} |y_i - \hat{y}_i|$$
 (10)

RMSE =
$$\sqrt{\frac{1}{n} \sum_{i=1}^{n} (y_i - \hat{y}_i)^2}$$
 (11)

式中: y_i 一真实值; y_i 一预测值。

评价指标计算结果如表3所示。

Tab. 3 Algorithm prediction error

算 法	R^2	MAE/kW	RMSE/kW
SVR	0.534 0	305.569 9	429.544 3
RF	0.968 1	24.755 3	50.131 9
LSTM	0.985 8	20.327 5	34.425 8
RF-SVR	0.986 3	19.8869	32.574 3

由表 3 可知,4 种预测模型中直接使用 SVR 模型的预测效果最差,预测误差远大于其他 3 种模型。 这是由于该方法仅使用单一的超平面进行预测,在 特征参数众多、数据量较大的情况下,极易受异常值 影响,难以实现稳定预测。RF,SVR,LSTM 和 RF-SVR 算法对比中,LSTM 与 RF-SVR 算法的预测精度更 高,MAE 分别为 20.32 和 19.88 kW,能够实现稳定 的风力发电预测。

为了更直观地分析模型预测效果,以一致性直 线为基础,对模型预测值与验证集真实值进行了一 对一的对比分析,如图 5 所示。图中一致性直线为 斜率为 45°的辅助参考线,表示实际值和预测值之 间的一致性。模型预测效果越好,则图中预测结果 的分布应更接近一致性直线。显然,SVR 模型的效 果最差,本文 RF-SVR 算法的预测精度较高。





3.4 真实实验验证

为充分证明本文算法的有效性,选择另一组风 力发电系统的实测数据进行了实验验证。实验输入 为待预测时间前一个月内的发电系统传感器实际测 量值,预测结果设置为未来 12 h 风力发电系统输出 功率,单次预测间隔为 10 min。实验中选择了两种 算法进行对比,分别为支持向量回归以及本文提出 的 RF-SVR 算法。RF-SVR 算法和支持向量回归模 型的预测结果如图 6 所示。



Fig. 6 Comparison of algorithm prediction results

由图 6 可知, RF-SVR 算法与随机森林模型皆 可实现较为精确的功率预测, RF-SVR 算法的平均 预测精度更高。实验数据证实了本文 1.1 节提出的 特征筛选算法对数据异常值和误差数据处理的有效 性。在 14:40~15:00 时间段,由于部分测量数据的 异常,支持向量回归模型会受到较大影响,预测值大 幅偏离真实值。14:50 时刻的发电系统实际发电功 率为1539.7 kW,而支持向量回归模型给出的预测 值为991.9 kW,而 RF-SVR 算法实现了稳定的风力 发电预测,预测结果为1513.6 kW。

4 结 论

以二叉回归树、随机森林模型、特征筛选和支持 向量回归为基础构建了一种 RF-SVR 风力发电功率 预测模型。通过实验结果分析,结论如下:

(1) RF-SVR 算法在处理大型风力发电数据集时,能够有效处理多维非线性特征,预测精度和计算 速度优于传统算法。

(2) RF-SVR 算法能够有效降低异常测量数据 的影响,并快速收敛至真实值附近,保持较高的预测 准确性。

参考文献:

- [1] 赵冬梅,杜 刚,刘 鑫,等.基于时序分解及机器学习的风电 功率组合预测模型[J].现代电力,2022,39(1):9-19.
 ZHAO Dongmei, DU Gang, LIU Xin, et al. Wind power combination prediction model based on time series decomposition and machine learning[J]. Modern Electric Power,2022,39(1):9-19.
- [2] 郑 培,于立军,侯胜亚,等. 基于卡尔曼滤波修正的多步风电 功率预测[J]. 热能动力工程,2020,35(4):235-241.
 ZHENG Pei,YU Lijun, HOU Shengya, et al. Multi-step wind power forecasting based on Kalman filter modification [J]. Journal of Engineering for Thermal Energy and Power,2020,35(4):235-241.
- [3] 颜全椿,顾 文,范立新,等. 储能协助风电机组参与电网调频 控制策略研究[J]. 现代电力,2022,39(5):537-546.
 YAN Quanchun, GU Wen, FAN Lixin, et al. Energy storage assists wind turbines to participate in grid frequency regulation control strategy research [J]. Modern Electric Power, 2022, 39(5): 537-546.
- [4] NIU Z, YU Z, TANG W, et al. Wind power forecasting using attention-based gated recurrent unit network [J]. Energy, 2020, 196: 117081.1 - 117081.17.

- [5] 张爱枫,段新宇,何枭峰. 基于 CNN 和 LightGBM 的新型风电功率预测模型[J]. 电测与仪表,2021,58(11):121-127.
 ZHANG Aifeng, DUAN Xinyu, HE Xiaofeng. A new wind power prediction model based on CNN and LightGBM [J]. Electrical Measurement & Instrumentation,2021,58(11):121-127.
- [6] KHALID M, SAVKIN A V. A method for short-term wind power prediction with multiple observation points [J]. IEEE Transactions on Power Systems, 2012, 27(2):579 – 586.
- [7] SHEN Z, RITTER M. Forecasting volatility of wind power production[J]. Applied Energy, 2016, 176:295 - 308.
- [8] CHEN P, PEDERSEN T, BAKJENSEN B, et al. ARIMA-based time series model of stochastic wind power generation [J]. IEEE Transactions on Power Systems, 2010, 25 (2):667-676.
- [9] 张颖超,成金杰,邓 华,等. 基于相似日和特征提取的短期风电功率预测[J]. 郑州大学学报(工学版),2020,41(5):44-49.
 ZHANG Yingchao, CHENG Jinjie, DENG Hua, et al. Short-term

wind power prediction based on similar day and feature extraction [J]. Journal of Zhengzhou University (Engineering Science), 2020,41(5):44-49.

- [10] 刘宏伟,陈永杰,郑 楠,等. 基于 LSTM 循环神经网络的风力 发电预测[J].可再生能源,2020,38(9):1187-1191.
 LIU Hongwei, CHEN Yongjie, ZHENG Nan, et al. Wind power forecast based on LSTM cyclic neural network [J]. Renewable Energy,2020,38(9):1187-1191.
- [11] 葛阳鸣.基于集成学习的短期风力发电功率预测研究[D].
 南京:南京邮电大学,2019.
 GE Yangming. Research on short-term wind power prediction based on integrated learning[D]. Nanjing: Nanjing University of Posts and Telecommunications,2019.
- [12] 姚 越,刘 达.基于注意力机制的卷积神经网络-长短期
 记忆网络的短期风电功率预测[J].现代电力,2022,39(2):
 212-218.

YAO Yue, LIU Da. Short-term wind power forecasting based on attention mechanism of CNN-LSTM[J]. Modern Electric Power, 2022,39(2):212-218.

(姜雪梅 编辑)