

基于气象特征挖掘和改进深度学习模型的风电功率短期预测

杨京渝^{1,2}, 罗隆福¹, 阳同光², 彭丽², 田飞扬²

(1. 湖南大学 电气与信息工程学院, 湖南 长沙 410000;

2. 湖南城市学院 智慧城市能源感知与边缘计算湖南省重点实验室, 湖南 益阳 413000)

摘要:为提高风电功率短期预测的准确度,需进一步挖掘气象特征,为此,提出一种基于贝叶斯优化调参的特征挖掘改进深度学习模型。对气象因素提取多时间尺度下的统计特征、组合特征和类别特征;构建包含长短时记忆神经网络与注意力机制结合模块、Embedding模块和输出模块的深度学习模型,将连续数值特征输入长短时记忆神经网络与注意力机制结合模块,将类别特征输入Embedding模块;由贝叶斯优化调参进行特征组合选择,找出最优特征组合,得到最终的风电功率预测结果。与某风电场历史数据的对比分析表明,所提方法能有效提高风电功率的预测精度。

关键词:风电功率预测;气象特征;深度学习;特征构造;贝叶斯优化

中图分类号:TM614

文献标志码:A

DOI:10.16081/j.epae.202208019

0 引言

当前,加快构建清洁低碳、安全高效的能源体系,持续推进碳减排,已经成为能源电力行业的共识。风力发电作为一种清洁能源日益受到重视并得到了长足的发展^[1],但由于风电功率受气象因素影响较大,其曲线呈现较强的波动性和随机性,大量风电在并网时将对电网的系统运行和调度产生巨大的冲击和影响^[2]。精确有效的风电功率预测在提高电力系统的安全稳定运行能力、改善电能质量等方面都具有重要的意义^[3]。

国内外已有不少学者对风电功率预测开展了深入的研究,常用的预测方法有物理方法、统计学方法和空间相关性方法三大类,其中统计学方法又可分为直接预测方法和间接预测方法^[4-5]。物理方法中有基于数值天气预报(numerical weather prediction, NWP)、基于卫星影像和云移动模型3种基础模型,但这类预测方法需要卫星云图的额外信息,导致成本较高。相比于物理方法,直接预测方法建模简单,不依赖于NWP数据,常用的建模方法有自回归滑动

平均模型、马尔可夫链蒙特卡罗模型等^[6-7],但这类方法存在需要大量的历史数据支持、无法对新建风电场进行功率预测等问题,最重要的是其忽略了风速、风向、湿度、温度等气象信息,不完备的特征信息难以保证预测精度。

间接预测首先预测出与风电功率相关的气象因素,然后将预测出的气象因素作为特征,预测对应时刻的风电功率,如BP神经网络^[8](back propagation neural network, BPNN)、支持向量机^[9]、最小二乘支持向量机^[10]均取得了较好的预测效果。文献[11-12]选取风速、风向、气压、温度等气象信息作为影响风电场功率的因素,对历史日进行搜索,构成训练样本集,采用Chebyshev神经网络预测风电功率;文献[13-14]考虑相似日或者相似时段的风电功率,根据不同天气类型对风电功率预测建立支持向量机、自适应脊波神经网络模型。相较于物理方法和直接预测方法,虽然间接预测方法具有考虑信息较完备、预测精度高等优点,但由于浅层神经网络算法难以对输入气象特征的深层特征进行挖掘,限制了模型的预测精度。

为了克服浅层网络的不足,在机器学习领域中,深度学习算法受到越来越多的关注。深度学习算法包括长短时记忆^[15](long short term memory, LSTM)神经网络、卷积神经网络^[16](convolution neural network, CNN)、注意力(Attention)机制^[17]、Embedding^[18]等算法,这些算法均有适合的应用场景。其中LSTM神经网络和CNN在风电功率预测中的应用较为广泛^[19-21]。文献[22]通过将数据输入LSTM神经网络模型和极限学习机模型,完成了对风电场风速的短期预测;文献[23]提出一种结合CNN与简单循环单

收稿日期:2022-03-11;修回日期:2022-05-14

在线出版日期:2022-08-11

基金项目:湖南省科技重大专项(2020GK1013);湖南省自然科学基金面上项目(2021JJ30079);湖南省教育厅科研项目(20C0358);益阳市社科课题(2022YS016)

Project supported by the Major Science and Technology Project of Hunan Province(2020GK1013), the Natural Science Foundation General Program of Hunan Province(2021JJ30079), the Scientific and Research Program of Educational Commission of Hunan Province(20C0358) and the Social Science Program of Yiyang City(2022YS016)

元的预测方法。上述研究证明了深度学习模型能够较好地拟合风电功率曲线,而且不同的深度学习层模型有不同的优点和缺点。为了充分发挥深度学习的优势,需要选择适合的深度学习模型,并将不同的深度学习模型进行连接,以此来提高风电功率的预测精度,因此,本文提出一种基于贝叶斯优化调参的气象特征挖掘改进深度学习模型,本文的贡献主要在以下2个方面。

1)对与风电功率有关的气象特征进行深度挖掘,构造更多的有效特征,为提高预测模型的精度创造了良好的先决条件。

2)构建一个用于风电功率预测的改进深度学习模型,模型各部分作用如下:LSTM神经网络用于输入气象特征和记忆历史信息;Attention机制用于重点注意LSTM神经网络输出序列中的重要信息;Embedding用于学习类别特征;贝叶斯优化调参用于选择最优特征。

1 风电功率预测理论基础

1.1 气象特征构造

特征是决定预测模型精度的核心因素,因此需要对与风电功率有关的气象特征进行深度挖掘,构造出更多的有效特征。将相关气象特征以 $Y=[Y_1, Y_2, \dots, Y_n]^T$ 表示,其中 $Y_i=[y_{i1}, y_{i2}, \dots, y_{iM}](i=1, 2, \dots, n)$ 为第 i 个时刻样本的特征, $y_{ik}(k=1, 2, \dots, M)$ 为 Y_i 中的第 k 个特征, n 为样本数, M 为气象特征数。构建如下特征。

1)原始特征,即 $Y=[Y_1, Y_2, \dots, Y_n]^T$ 。

2)时间特征。从时间中提取该年第几月、该月第几日、该周星期几、该天第几小时、该小时第几分钟共5个时间特征。例如2016-02-22T15:30:00对应的的时间特征如下:该年第几月为2,该月第几日为22,该周星期几为1,该天第几小时为15,该小时第几分钟为30。

3)组合特征。组合特征包含线性组合特征和非线性组合特征,前者用于挖掘特征间的线性关系,后者用于挖掘特征间的非线性关系,具体计算公式如式(1)所示。

$$\begin{cases} f_{ia}=y_{ij}+y_{ik} \\ f_{is}=y_{ij}-y_{ik} \\ f_{im}=y_{ij}y_{ik} \\ f_{id}=y_{ij}/y_{ik} \end{cases} \quad (1)$$

式中: $j, k=1, 2, \dots, M$; $f_{ia}, f_{is}, f_{im}, f_{id}$ 分别为第 i 个时刻样本的加性、减性、乘性、除性特征。

4)统计特征。统计特征用于表示时间窗内的数据波动情况,该特征可表示为:

$$\begin{cases} \bar{y}_{ikt_w} = \frac{1}{2t_w+1} \sum_{v=-t_w}^{t_w} y_{(i+v)k} \\ S_{ikt_w} = \left[\frac{1}{2t_w+1} \sum_{v=-t_w}^{t_w} (y_{(i+v)k} - \bar{y}_{ikt_w})^2 \right]^{\frac{1}{2}} \\ y_{\max kt_w} = \max \{ y_{(v-t_w)k}, y_{(v-t_w+1)k}, \dots, y_{(v+t_w)k} \} \end{cases} \quad (2)$$

式中: $\bar{y}_{ikt_w}, S_{ikt_w}, y_{\max kt_w}$ 分别为 $[i-t_w, i+t_w]$ 时间窗内第 k 个特征的均值、标准差和最大值; t_w 为时间窗参数,表示时间窗内时刻数。

1.2 LSTM神经网络

LSTM神经网络能够很好地解决序列的长期依赖问题,其结构如附录A图A1所示。LSTM神经网络可以由时间展开表示成链状结构,其重复模块中有4个神经网络层。对应的参数为:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (3)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (4)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (5)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (6)$$

$$O_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (7)$$

$$h_t = O_t \tanh C_t \quad (8)$$

式中: f_t, i_t, O_t 分别为当前时刻 t 的遗忘门输出、输入门输出、输出门输出; W_f, b_f 分别为遗忘门的权重和偏置; W_i, b_i 分别为输入门的权重和偏置; W_c, b_c 分别为更新值的权重和偏置; W_o, b_o 分别为输出门的权重和偏置; $\sigma(\cdot)$ 表示Sigmoid激活函数; x_t, C_t, h_t 分别为当前时刻 t 的输入、细胞状态和LSTM神经网络单元的输出值; C_{t-1}, h_{t-1} 分别为前一时刻的细胞状态和LSTM神经网络单元的输出值; $[h_{t-1}, x_t]$ 表示将行数相等的矩阵进行列合并; $\tilde{C}_t$ 为候选细胞状态;“*”表示点乘。

1.3 Attention机制

当有大量的输入信息输入神经网络时,不同输入值对输出值的影响不同。为提升神经网络的工作效率,对于同一输出,需将更多的运算力分配到重要输入信息上,为此,引入Attention机制,其结构如附录A图A2所示。图中: $x_{i_a}(i_a=1, 2, \dots, N)$ 为第 i_a 个输入值, N 为输入值个数; q 为神经网络的输出状态; α_{i_a} 为所有的输入值针对输出状态 q 的Attention分布值; a 为注意力层的输出; $S(\cdot, \cdot)$ 为Attention打分函数,如式(9)所示。

$$S(x_{i_a}, q) = x_{i_a}^T W q \quad (9)$$

式中: W 为可自主学习的神经网络参数。将式(9)中的Attention打分函数进行Softmax取值即可得到Attention分布值 α_{i_a} ,如式(10)所示。

$$\alpha_{i_a} = \text{Softmax}(S(x_{i_a}, q)) \quad (10)$$

式中:Softmax($\cdot$)表示Softmax激活函数。

最后,将Attention分布值 α_{i_s} 与输入值 x_{i_s} 加权平均得到 a ,如式(11)所示。

$$a = \sum_{i_s=1}^N \alpha_{i_s} x_{i_s} \quad (11)$$

1.4 Embedding

为保证网络能学习到时间、风速等类别信息,本文采用在自然语言处理中普遍使用的Embedding结构。Embedding是一种对离散类别特征进行映射的结构,假设风速类别数目为 D ,经过Embedding编码后得到一个 $D \times n_{\text{emb}}$ 阶的矩阵,其中 n_{emb} 为潜在特征数量,对其他时间特征也进行同样的处理。

2 贝叶斯优化调参

贝叶斯优化过程常用于机器学习最优参数的选择,为减少模型计算量以及找到最优特征组合,本文对时间窗参数 t_w 、提取统计特征的特征数 n_{um1} 和进行特征组合的特征数 n_{um2} 进行贝叶斯优化调参,用于约束特征维度和模型参数调优,构建样本参数组合 $[p_1, p_2, \dots, p_q]$,其中 $p_s (s=1, 2, \dots, q)$ 为第 s 个特征组合, q 为特征组合数。采用贝叶斯优化调参的步骤如下。

1) 高斯过程估计。

首先在构建的样本参数组合中选取 r 个特征组合 $[p_1, p_2, \dots, p_r]$,分别计算对应的损失函数 $[L(p_1), L(p_2), \dots, L(p_r)]$,其中 $L(p_s) (s=1, 2, \dots, r)$ 为第 s 个特征组合对应的损失函数,然后将样本参数和损失函数进行组合得到 D_r ,如式(12)所示。

$$D_r = \left\{ (p_s, L(p_s)), s=1, 2, \dots, r \right\} \quad (12)$$

估计损失函数服从高斯分布,则 $[L(p_1), L(p_2), \dots, L(p_r)]$ 的高斯分布为:

$$\left\{ \begin{aligned} & [L(p_1), L(p_2), \dots, L(p_r)] \sim N(0, K) \\ & K = \begin{bmatrix} k(p_1, p_1) & \dots & k(p_1, p_r) \\ \vdots & & \vdots \\ k(p_r, p_1) & \dots & k(p_r, p_r) \end{bmatrix} \end{aligned} \right. \quad (13)$$

式中: $k(\cdot, \cdot)$ 为核函数,表示协方差。

2) 选取采样点。

通过比较新采样点和当前采样点的损失函数期望确定新的采样点,该数学期望被称为期望增量(expected improvement, EI)函数。本文采用树状结构Parzen估计算法建立EI函数,假设 p^* 为当前最优参数组合,将比 $L(p^*)$ 大的值 y^* 作为阈值,数学期望函数 $E(\cdot)$ 可通过式(14)得到。

$$\left\{ \begin{aligned} E(p_s) &= \int_{-\infty}^{y^*} (y^* - y) P(y|p_s) dy = \\ &= \frac{\gamma y^* \ell(p_s) - \ell(p_s) \int_{-\infty}^{y^*} P(p_s) dy}{\gamma \ell(p_s) + (1 - \gamma) g(p_s)} \\ P(p_s|y) &= \begin{cases} \ell(p_s) & y \leq y^* \\ g(p_s) & y > y^* \end{cases} \end{aligned} \right. \quad (14)$$

式中: $P(\cdot)$ 为概率密度函数, $P(y|p_s)$ 为 p_s 出现时 y 出现的概率, $P(p_s|y)$ 为 y 出现时 p_s 出现的概率, $P(p_s)$ 为 p_s 出现的概率; γ 为分布比重; $\ell(p_s)$ 为 $y \leq y^*$ 时的分布函数; $g(p_s)$ 为 $y > y^*$ 时的概率密度函数。

将使得函数 $E(\cdot)$ 取最大值的点作为采样点,得到新的最优参数组合 p_{new} ,如式(15)所示。

$$p_{\text{new}} = \operatorname{argmax} E(p_s) \quad (15)$$

式中: $\operatorname{argmax} E(p_s)$ 表示求使得数学期望函数最大的参数。

3) 更新 $L(p_s)$ 的高斯分布。

在增加了新样本后,新的高斯分布为:

$$\left\{ \begin{aligned} & [L(p_1), L(p_2), \dots, L(p_r), L(p_{\text{new}})] \sim \\ & N\left(0, \begin{bmatrix} K & k' \\ (k')^T & k(p_{\text{new}}, p_{\text{new}}) \end{bmatrix}\right) \\ & k' = [k(p_{\text{new}}, p_1), k(p_{\text{new}}, p_2), \dots, k(p_{\text{new}}, p_r)]^T \end{aligned} \right. \quad (16)$$

根据式(17)计算得到 $L(p_{\text{new}})$ 的新分布 $P(L(p_{\text{new}}|D_r, p_{\text{new}}))$ 。

$$\left\{ \begin{aligned} & P(L(p_{\text{new}}|D_r, p_{\text{new}})) \sim N(\mu, \sigma^2) \\ & \mu = (k')^T K^{-1} [L(p_1), L(p_2), \dots, L(p_r)]^T \\ & \sigma^2 = k(p_{\text{new}}, p_{\text{new}}) - (k')^T K^{-1} k' \end{aligned} \right. \quad (17)$$

式中: μ, σ 分别为均值、标准差。

4) 循环步骤2)、3),直至达到最大迭代步数,并计算出当前最优输出点。

3 改进深度学习的风电功率预测模型

3.1 改进深度学习模型网络结构

为了更好地学习数值特征和类别特征,本文构建一个改进的LSTM神经网络用于风电功率预测,整个模型由LSTM神经网络与Attention机制结合模块、Embedding模块、输出模块三大部分组成,每个部分的连接图如附录A图A3所示。其中LSTM神经网络与Attention机制结合模块用于学习天气数值特征,Embedding模块用于学习类别特征,然后将这2个模块的输出通过Merge层融合后输入输出模块,通过贝叶斯优化调参进行特征组合选择,最终得到风电功率预测结果。

1) LSTM 神经网络与 Attention 机制结合模块是由 2 层 LSTM 神经网络连接 2 层全连接层构成的,且在其中添加了残差连接,该连接能够解决多层神经网络可能出现的梯度消失问题。然后再连接 1 个 Attention 机制层用于关注重点信息,最后再连接 2 层带有残差操作的全连接层。

2) Embedding 模块给每个类别特征均进行 Embedding 编码,然后进行融合,最终输出至 2 层全连接层,全连接层上同样添加了残差连接。

3) 输出模块用于输出预测结果,采用 2 个全连接层连接到输出层。

3.2 风电功率预测流程

本文提出基于特征挖掘的模型融合风电功率预测方法。首先通过对气象特征挖掘时间窗口 $[i-t_w, i+t_w]$ 下的统计特征和相应的组合特征外加时间特征构造;然后采用贝叶斯优化调参选出最优时间窗口参数 t_w 和特征组合的特征数 n_{um1} 、 n_{um2} ,找出最优时间窗口并减少特征冗余度;最终得到训练好的风电功率预测模型。风电功率预测流程图如图 1 所示。




图1 风电功率预测流程图

Fig.1 Flowchart of wind power forecasting

3.3 评价指标

为了定量分析预测结果,验证本文所提预测模型的有效性,采用可决系数(R-squared, R^2)、绝对平均误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)、平均误差(mean error, ME)对模型进行评价,分别如式(18)~(21)所示。

$$R^2 = 1 - \frac{\sum_{i=0}^{N_s-1} (y_i - \hat{y}_i)^2}{\sum_{i=0}^{N_s-1} (y_i - \bar{y})^2} \quad (18)$$

$$e_{MAE} = \frac{1}{N_s} \sum_{i=0}^{N_s-1} |y_i - \hat{y}_i| \quad (19)$$

$$e_{RMSE} = \sqrt{\frac{1}{N_s} \sum_{i=0}^{N_s-1} (y_i - \hat{y}_i)^2} \quad (20)$$

$$e_{ME} = \frac{1}{N_s} \sum_{i=0}^{N_s-1} (y_i - \hat{y}_i) \quad (21)$$

式中: e_{MAE} 、 e_{RMSE} 、 e_{ME} 分别为 MAE、RMSE、ME; N_s 为预测样本数; y_i 、 $\hat{y}_i$ 分别为第 i 个时刻样本的真实值和预测值; $\bar{y}$ 为实际样本的均值。

4 算例仿真

4.1 算例数据及仿真环境

为验证本文所提方法的通用性,选取某座风电场 2014-07-01T00:00:00 至 2015-12-31T24:00:00 时间段的实际风电功率数据及气象数据作为训练样本,样本数据包括时间、风速、风向、温度、压强、湿度和实际功率。风电场数据采样间隔为 15 min,将前 509 d (2014-07-01T00:00:00 至 2015-11-21T24:00:00) 共计 48 864 组数据作为训练集对模型进行训练,将后 40 d (2015-11-22T00:00:00 至 2015-12-31T24:00:00) 共计 3 840 组数据作为测试集对模型进行评估。

仿真的硬件为 CPU i7-7000, GPU 1050Ti 4 GB, 内存 16 GB。选择 Python 语言进行编程,利用 numpy、pandas 库进行数据处理,利用 Hyperopt 库进行贝叶斯优化调参,利用 keras 库搭建深度学习模型。

4.2 气象特征构造与优化

根据 1.1 节中的特征构造方法,原始特征包含风速、温度、湿度、气压、风向这 5 个特征,每个特征提取 3 个统计特征,共计 15 个统计特征。在增加的组合特征中,由于加法和乘法有可交换性,共增加 $2C_{20}^2 = 380$ 个特征,由于减法和除法不满足交换性,共增加 $2 \times 2C_{20}^2 = 760$ 个特征,额外加上 5 个时间特征和 1 个风向特征,共有 1 166 个特征。

图 2 展示了原始特征和构造特征与实发功率的线性相关性,相关性在 0~1 之间取值,数值越大,表示相关性越高。从图 2(a)中可知,仅风速与实发功率具有高相关性;从图 2(b)中可知,构造特征中增加了较多与实发功率相关性高的特征,充分说明了特征构造的作用,这使得模型增加了更多的有效特征。

过多的特征导致模型训练时间大幅增加,因此,利用贝叶斯调参方法对特征参数进行优化,减少特征总数,选取有效特征。参数搜索空间设置如表 1 所示。

采用改进的深度学习模型,以 NWP 作为输入,对风电功率进行拟合。采用贝叶斯优化方法对特征进行选择,该方法根据模型特征对模型拟合误差影响的大小来判断特征对风电功率的影响程度,自动





图2 原始特征与构造特征的相关性图

Fig.2 Correlation graph of original features and constructed features

表1 参数搜索空间设置

Table 1 Setting of parameter searching space

参数	取值区间	采样方式
t_w	[1, 96]	离散随机采样
n_{um1}	[1, 5]	离散随机采样
n_{um2}	[2, 15]	离散随机采样

挑选出使得模型拟合误差小的气象特征,共计挑选出风速、风向、气压这3个统计特征,以及风速、风向、风速标准差、风向标准差、气压、温度均值、气压均值、气压最大值、温度、湿度均值、温度均值、气压标准差这12个组合特征。

4.3 预测模型及参数设定

为验证本文方法的有效性和优越性,对如下4

种模型进行对比分析,采用多点预测的直接预测方法预测后面24 h(96个时间点)的风电功率:预测模型1,将原始特征作为输入,采用BPNN模型完成对风电功率预测模型的训练和预测;预测模型2,将原始特征作为输入,采用未进行特征提取的LSTM神经网络模型完成对风电功率预测模型的训练和预测;预测模型3,将利用1.1节方法构造的特征作为输入,采用未经过贝叶斯优化调参的改进深度学习模型完成对风电功率预测模型的训练和预测;预测模型4,将利用1.1节方法构造的特征作为输入,采用基于贝叶斯优化调参的改进深度学习模型完成对风电功率预测模型的训练和预测。

本文所采用的改进深度学习模型的参数如表2所示。LSTM神经网络和BPNN的参数如表3所示,表中LSTM(128)表示该层有128个LSTM神经网络神经元,FC(32)表示该层有32个全连接神经元,层与层之间用“-”连接。

表2 改进深度学习模型参数

Table 2 Parameters of improved deep learning model

参数	设定值	参数	设定值
学习率	0.001	轮次	300
批量大小	100	优化方法	Adam
损失函数	MSE		

表3 LSTM神经网络和BPNN的参数

Table 3 Parameters of LSTM neural network and BPNN

模型	参数
LSTM	LSTM(128)-LSTM(64)-FC(32)-FC(1)
BPNN	FC(128)-FC(64)-FC(32)-FC(1)

4.4 预测结果分析

各预测模型后40 d的风电功率预测误差评价指标如表4所示。

表4 不同模型的预测误差评价指标

Table 4 Evaluation indexes of forecasting errors for different models

预测模型	$R^2 / \%$	e_{MAE} / MW	e_{RMSE} / MW	e_{ME} / MW
1	0.508 1	6.825 6	8.774 4	-1.041 4
2	0.650 1	6.552 0	8.721 6	7.369 0
3	0.687 8	6.379 2	8.289 6	5.617 9
4	0.718 1	5.760 0	7.876 8	-0.510 1

由表4可知:相较于预测模型1—3,预测模型4的 e_{MAE} 指标分别下降了1.065 6、0.792 0、0.612 9 MW,降幅分别为15.61%、12.09%、9.71%; e_{RMSE} 指标分别下降了0.897 6、0.844 8、0.412 8 MW,降幅分别为10.23%、9.69%、4.98%; R^2 指标分别提升41.33%、10.46%、4.41%。由此可知,经过贝叶斯优化调参的改进深度学习预测模型的效果最佳,未经过贝叶斯优化调参的改进深度学习预测模型的效果次之,然后

是LSTM神经网络模型,BPNN模型预测效果最差。

附录A图A4为在4种预测模型的预测结果中随机提取2 d的预测结果与真实值的对比分析图。附录A图A5为对应的预测误差评价指标MAE的曲线图。结合图A4和图A5可以看出,预测模型4的结果更加接近真实值的变化趋势,相比其他模型有较明显的优势。

从上述预测结果可以得出,对于风电功率整体预测效果,经过气象特征构造的预测模型3和预测模型4的准确率比未经过特征构造的预测模型1和预测模型2有明显提高,充分证明了特征构造以及贝叶斯优化调参的有效性,二者均可有效提高风电功率预测的准确率。

5 结论

准确预测风电功率是解决高比例风电并网所带来的问题的有效途径。本文构造风电功率相关气象特征,并提出一种基于贝叶斯优化调参的改进深度学习模型,以提高风电功率预测准确率。算例验证得到以下结论。

1)所建模型进一步挖掘风电相关的气象特征,找出特征间信息,并利用贝叶斯优化调参剔除冗余特征。

2)所建模型在高精度预测风电功率的同时能够自动筛选出对风电功率影响较大的气象特征,仿真结果证明,在该模型下影响最大的气象特征为风速和风向,且两者的构造特征风速标准差、风向标准差对风电功率也具有较大影响。

3)所提方法可以有效提高风电功率预测的准确率。未经过贝叶斯优化调参的改进深度学习模型相比于其他模型可以有效提高风电功率预测的精度,但经过贝叶斯优化调参的改进深度学习模型的预测结果更加准确,且学习样本数量更多,准确率更高。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 肖白,邢世亨,王茂春,等. 基于改进KDE法和GA-SVM的多风电场聚合后输出功率长期波动特性预测方法[J]. 电力自动化设备,2022,42(2):77-84.
XIAO Bai, XING Shiheng, WANG Maochun, et al. Prediction method of output power long-term fluctuation characteristic for multiple wind farms after aggregation based on improved KDE method and GA-SVM[J]. Electric Power Automation Equipment, 2022, 42(2): 77-84.
- [2] 黎静华,黄玉金,黄乾. 基于改进混沌时间序列的风电功率区间预测方法[J]. 电力自动化设备,2019,39(5):53-60,68.
LI Jinghua, HUANG Yujin, HUANG Qian. Interval prediction method of wind power based on improved chaotic time series[J]. Electric Power Automation Equipment, 2019, 39(5): 53-60, 68.
- [3] 沈小军,周冲成,付雪娇. 基于机联网-空间相关性权重的风电机组风速预测研究[J]. 电工技术学报,2021,36(9):1782-1790,1817.
SHEN Xiaojun, ZHOU Chongcheng, FU Xuejiao. Wind speed prediction of wind turbine based on the Internet of machines and spatial correlation weight[J]. Transactions of China Electrotechnical Society, 2021, 36(9): 1782-1790, 1817.
- [4] 杨茂,代博社. 基于比恩法的风电场风速-功率曲线建模误差分析[J]. 电力自动化设备,2020,40(12):81-89.
YANG Mao, DAI Bozhi. Modeling error analysis of wind speed-wind power curve for wind farm based on Bins method[J]. Electric Power Automation Equipment, 2020, 40(12): 81-89.
- [5] 杨茂,张罗宾,崔杨,等. 基于混合半云模型的风速-功率曲线建模方法[J]. 电力自动化设备,2020,40(5):106-114.
YANG Mao, ZHANG Luobin, CUI Yang, et al. Wind speed-power curve modeling method based on hybrid half-cloud model[J]. Electric Power Automation Equipment, 2020, 40(5): 106-114.
- [6] 唐振浩,赵赓楠,曹生现,等. 基于SWLSTM算法的超短期风向预测[J]. 中国电机工程学报,2019,39(15):4459-4468.
TANG Zhenhao, ZHAO Gengnan, CAO Shengxian, et al. Very short-term wind direction prediction via self-tuning wavelet long-short term memory neural network[J]. Proceedings of the CSEE, 2019, 39(15): 4459-4468.
- [7] 杨锡运,张艳峰,叶天泽,等. 基于朴素贝叶斯的风电功率组合概率区间预测[J]. 高电压技术,2020,46(3):1099-1108.
YANG Xiyun, ZHANG Yanfeng, YE Tianze, et al. Prediction of combination probability interval of wind power based on naive Bayes[J]. High Voltage Engineering, 2020, 46(3): 1099-1108.
- [8] 周小麟,童晓阳. 基于CEEMD-SBO-LSSVR的超短期风电功率组合预测[J]. 电网技术,2021,45(3):855-864.
ZHOU Xiaolin, TONG Xiaoyang. Ultra-short-term wind power combined prediction based on CEEMD-SBO-LSSVR[J]. Power System Technology, 2021, 45(3): 855-864.
- [9] 叶林,刘鹏. 基于经验模态分解和支持向量机的短期风电功率组合预测模型[J]. 中国电机工程学报,2011,31(31):102-108.
YE Lin, LIU Peng. Combined model based on EMD-SVM for short-term wind power prediction[J]. Proceedings of the CSEE, 2011, 31(31): 102-108.
- [10] HU Q H, ZHANG R J, ZHOU Y C. Transfer learning for short-term wind speed prediction with deep neural networks[J]. Renewable Energy, 2016, 85: 83-95.
- [11] 王贺,胡志坚,仇梦林. 基于模糊信息粒化和最小二乘支持向量机的风电功率波动范围组合预测模型[J]. 电工技术学报,2014,29(12):218-224.
WANG He, HU Zhijian, ZHANG Menglin. A combined forecasting model for range of wind power fluctuation based on fuzzy information granulation and least squares support vector machine[J]. Transactions of China Electrotechnical Society, 2014, 29(12): 218-224.
- [12] CHEN N Y, QIAN Z, NABNEY I T, et al. Wind power forecasts using Gaussian processes and numerical weather prediction[J]. IEEE Transactions on Power Systems, 2014, 29(2): 656-665.
- [13] 丁志勇,杨萃,杨曦,等. 基于连续时间段聚类的支持向量机风电功率预测方法[J]. 电力系统自动化,2012,36(14):131-135,149.
DING Zhiyong, YANG Ping, YANG Xi, et al. Wind power prediction method based on sequential time clustering support vector machine[J]. Automation of Electric Power Systems, 2012, 36(14): 131-135, 149.
- [14] 张宜阳,严欢. 基于分段分层相似日搜索和自适应脊波神经网络

- 络的风电功率多步预测[J]. 电网与清洁能源, 2015, 31(4): 124-131.
- ZHANG Yiyang, YAN Huan. Multi-step wind power forecasting based on subsection and layer searching for similar day and adaptive ridgelet neural network[J]. Power System and Clean Energy, 2015, 31(4): 124-131.
- [15] 李彬, 彭曙蓉, 彭君哲, 等. 基于深度学习分位数回归模型的风电功率概率密度预测[J]. 电力自动化设备, 2018, 38(9): 15-20.
- LI Bin, PENG Shurong, PENG Junzhe, et al. Wind power probability density forecasting based on deep learning quantile regression model[J]. Electric Power Automation Equipment, 2018, 38(9): 15-20.
- [16] 栗然, 马涛, 张潇, 等. 基于卷积长短期记忆神经网络的短期风电功率预测[J]. 太阳能学报, 2021, 42(6): 304-311.
- LI Ran, MA Tao, ZHANG Xiao, et al. Short-term wind power prediction based on convolutional long-short-term memory neural networks[J]. Acta Energetica Sinica, 2021, 42(6): 304-311.
- [17] 李卓, 叶林, 戴斌华, 等. 基于IDSCNN-AM-LSTM组合神经网络超短期风电功率预测方法[J]. 高电压技术, 2022, 48(6): 2117-2127.
- LI Zhuo, YE Lin, DAI Binhua, et al. Ultra-short-term wind power prediction method based on IDSCNN-AM-LSTM combination neural network[J]. High Voltage Engineering, 2022, 48(6): 2117-2127.
- [18] 赵倩, 黄景涛. 基于EMD-SA-SVR的超短期风电功率预测研究[J]. 电力系统保护与控制, 2020, 48(4): 89-96.
- ZHAO Qian, HUANG Jingtao. On ultra-short-term wind power prediction based on EMD-SA-SVR[J]. Power System Protection and Control, 2020, 48(4): 89-96.
- [19] HU Y L, CHEN L. A nonlinear hybrid wind speed forecasting model using LSTM network, hysteretic ELM and differential evolution algorithm[J]. Energy Conversion and Management, 2018, 173: 123-142.
- [20] LÓPEZ E, VALLE C, ALLENDE H, et al. Wind power forecasting based on echo state networks and long short-term memory[J]. Energies, 2018, 11(3): 526.
- [21] LIU H, MI X W, LI Y F. Smart deep learning based wind speed prediction model using wavelet packet decomposition, convolutional neural network and convolutional long short term memory network[J]. Energy Conversion and Management, 2018, 166: 120-131.
- [22] LIU H, MI X W, LI Y F. Smart multi-step deep learning model for wind speed forecasting based on variational mode decomposition, singular spectrum analysis, LSTM network and ELM[J]. Energy Conversion and Management, 2018, 159: 54-64.
- [23] 王晨, 寇鹏. 基于卷积神经网络和简单循环单元集成模型的风电场多风机风速预测[J]. 电工技术学报, 2020, 35(13): 2723-2735.
- WANG Chen, KOU Peng. Wind speed forecasts of multiple wind turbines in a wind farm based on integration model built by convolutional neural network and simple recurrent unit[J]. Transactions of China Electrotechnical Society, 2020, 35(13): 2723-2735.

作者简介:



杨京渝

杨京渝(1986—), 男, 讲师, 博士研究生, 主要研究方向为新能源发电并网技术(E-mail: 443792056@qq.com);

罗隆福(1962—), 男, 教授, 博士研究生导师, 博士, 通信作者, 主要研究方向为新能源发电、电能变换系统与装备动态无功补偿技术、HVDC系统的关键技术与装备研制等(E-mail: llf@hnu.edu.cn)。

(编辑 王锦秀)

Wind power short-term forecasting based on meteorological feature exploring and improved deep learning model

YANG Jingyu^{1,2}, LUO Longfu¹, YANG Tongguang², PENG Li², TIAN Feiyang²

(1. School of Electrical & Information Engineering, Hunan University, Changsha 410000, China;

2. Key Laboratory Energy Monitoring and Edge Computing for Smart City of Hunan Province, Hunan City University, Yiyang 413000, China)

Abstract: In order to improve the accuracy of wind power short-term forecasting, further mining of meteorological features is needed, for which, an improved deep learning model for feature mining is proposed based on Bayesian optimal parameter tuning. The statistical features, combinatorial features and category features are extracted for meteorological factors under multiple time scales. A deep learning model consisting of module combining long short-term memory neural network and Attention mechanism, Embedding module and output module is constructed, the continuous numerical values are input into the module combining long short-term memory neural network and Attention mechanism, and the categorical features are input into the Embedding module. The Bayesian optimal parameter tuning is used for feature combination selection to find the optimal feature combination, and the final wind power forecasting results is obtain. The comparative analysis with historical data of a wind farm shows that the proposed method can effectively improve the forecasting accuracy of wind power.

Key words: wind power forecasting; meteorological feature; deep learning; feature exploring; Bayesian optimization

附录 A




图 A1 LSTM 结构

Fig.A1 LSTM structure





图 A2 Attention 结构

Fig.A2 Attention structure




(b) 第 23 天


—*— 真实值 —△— 预测模型1 —×— 预测模型2 —○— 预测模型3 —★— 预测模型4

图 A4 24 h 风电功率预测结果对比图

Fig.A4 Comparison diagram of 24 h wind power forecasting results



(a) 第 11 天



(b) 第23天

—△— 预测模型1 *— 预测模型2 —○— 预测模型3 *— 预测模型4

图 A5 24 h 风电功率预测误差对比图

Fig.A5 Comparison diagram of 24 h wind power forecasting errors