

基于优化小波变换神经网络的 分布式新能源信息预测方法

栾开宁¹, 庄 重², 杨世海², 段梅梅², 孔月萍², 周雨奇², 张汀荃², 丁泽诚²

(1. 国网江苏省电力有限公司, 江苏 南京 210019)

(2. 国网江苏省电力有限公司营销服务中心, 江苏 南京 210019)

[摘要] 分布式新能源发电是低碳化电力系统中重要的一部分。随着分布式新能源在城市电网中的占比逐渐增加, 负荷随机波动和天气随机变化对于城市电网的影响日益增强, 对分布式新能源信息的预测准确性提出了更高的要求。目前, 分布式新能源的主要发电方式是分布式光伏发电以及分布式风力发电。城市用电负荷的变化兼具周期性和随机性, 而风速和辐照强度等因素分别对于分布式风力发电和分布式光伏发电有重要影响。为了准确预测出分布式新能源的信息, 构建了基于小波变换神经网络的分布式新能源信息预测方法。首先, 通过分析分布式新能源的工作原理, 建立分布式新能源的模型; 然后, 优化小波变换神经网络, 以风力发电和光伏发电为例对负荷用电功率和辐照强度等对电网作用显著的参数进行预测; 最后, 算例验证模型对分布式新能源信息进行预测的准确性。

[关键词] 分布式新能源, 负荷预测, 辐照强度预测, 城市电网, 小波变换神经网络

[中图分类号] TM615 **[文献标志码]** A **[文章编号]** 1672-1292(2024)02-0011-09

Optimized Wavelet Transform Neural Networks for Accurate Distributed Renewable Energy Information Prediction

Luan Kaining¹, Zhuang Zhong², Yang Shihai², Duan Meimei², Kong Yueping²,
Zhou Yuqi², Zhang Tingquan², Ding Zecheng²

(1. State Grid Jiangsu Electric Power Co., Ltd., Nanjing 210019, China)

(2. Marketing Service Center of State Grid Jiangsu Electric Power Co., Ltd., Nanjing 210019, China)

Abstract: Distributed renewable energy generation is a crucial component of low-carbon power systems. As the proportion of distributed renewable energy in urban power grids is gradually increasing, and the impacts of random load fluctuations and random weather changes on urban power grids are increasing, placing higher demands on the accuracy of distributed renewable energy information forecasting. Currently, the primary generation methods of distributed renewable energy are distributed photovoltaic power generation and distributed wind power generation. The changes of urban electricity load are both cyclical and random, while factors such as wind speed and solar irradiance have significant impacts on distributed wind power generation and distributed photovoltaic power generation, respectively. Therefore, based on wavelet transform neural network, a distributed renewable energy information prediction method is constructed. Firstly, the model of distributed renewable energy is established by analyzing the working principle of distributed renewable energy. Then, the wavelet transform neural network is optimized to predict the parameters that play a significant role in the renewable energy grid, such as the load power change and the irradiation intensity, using wind power generation and photovoltaic power generation as examples. Finally, the example verifies that the proposed model can accurately predict the information of distributed renewable energy.

Key words: distributed renewable energy, load prediction, irradiation intensity prediction, urban power grid, wavelet transform neural network

收稿日期: 2024-04-10.

基金项目: 国家电网有限公司科技项目(J2022045).

通讯作者: 栾开宁, 博士, 高级工程师, 研究方向: 电力负荷预测与调控、智能用电. E-mail: luankaining2000@163.com

“双碳”目标是我国基于推动构建人类命运共同体的责任担当和实现可持续发展的内在要求而做出的重大战略决策,展示了我国为应对全球气候变化做出的新努力和新贡献,体现了重振全球气候行动的信心与希望,彰显了中国积极应对气候变化、走绿色低碳发展道路、推动全人类共同发展的坚定决心。这向全世界展示了应对气候变化的中国雄心和担当,使我国从应对气候变化的积极参与者、努力贡献者,逐步成为关键引领者。随着我国提出“双碳目标”、构建新型电力系统,能源发展方式由集中式、粗放式向分布式、集约、高效和绿色的转变再次提速。

分布式新能源发电将是未来低碳化电力系统中最重要的一部分^[1-4]。分布式能源可以将能源直接提供给周边区域的用户,实现能源的本地化供应和高效利用。相对于集中式能源,分布式发电系统以小规模、小容量、模块化的方式布置在用户附近。可就近满足用户对电力方面的需求^[5]。目前,分布式能源已经覆盖多种能源形式。其中,分布式光伏发电和分布式风电是最主要的分布式发电方式^[6]。

然而,由于受气候变化影响极大,分布式新能源发电功率具有波动性和间歇性。如分布式风电发电功率会受到风速的影响。分布式光伏发电功率会受到日照强度、环境温度等气候条件的影响。为了确保电力系统在引入分布式新能源后的安全性和稳定性,须准确预测新能源发电方式的输出信息。准确的新能源发电信息的预测可以为后续的运行方式调整提供有效依据,从而降低分布式新能源并网后引发的巨大冲击。

目前,针对分布式新能源的预测方法主要包括直接预测法与间接预测法。直接预测方法实质上是以数据统计为核心的预测方式,通过深入挖掘历史数据的规律和特征,从而有效地预估未来在不同气候条件下的分布式新能源输出情况。在保证光伏电池最大出力的情况下,利用一个 10kWp 光伏发电系统的实际运行数据分析了本地的光伏发电系统一般出力情况^[7]。对光伏发电模块的功率进行了建模,在考虑太阳辐照与温度的基础上,实现了对太阳能电池功率的预测^[8]。在 ARMA 时间序列的基础上,实现了对风电出力的预测^[9]。人工智能预测是利用人工神经网络进行预测的一种方法,其实质上属于直接预测方法。其主要技术包括:径向神经网络(support vector machine, SVM)、极限学习机(extreme learning machine, ELM)、反向神经(back propagation, BP)网络等^[10]。文献[11]针对多层感知器(multi-layer perceptron, MLP)在初始权重和偏置量中存在的随机性问题,提出运用改进灰狼算法(grey wolf optimizer, GWO)对 MLP 的初始权重和偏置量进行优化,提出了基于 GWO-MLP 的光伏系统输出预测模型。文献[12]提出了一种基于 PSO 的 Elman 神经网络预测算法,用以克服光伏功率随机性强的问题。为了进一步提升预测精度,有研究人员将各种方法结合起来构成组合预测方法。如文献[13]提出了基于 GWO 优化 SVM 与随机森林(random forest, RF)的组合预测模型,结合了几种算法的优点,克服了单一预测算法的局限性。

间接预测法对天气预报数据有较强的依赖性,无需借助任何分布式新能源发电站的历史数据。在这种方法中,数值天气预报是其中一种主要的技术手段。数值天气预报是一种利用气象探测仪器所采集的实际大气数据作为初始条件,借助超级计算机进行数值计算的方法。在预设的初始和边界条件下,它通过充分考虑大气运动情况和热力学过程,实现对未来天气情况的预测。文献[14]中,基于光伏发电机组的空间聚类 and 神经网络模型,利用数值天气预报数据来预测特定区域的光伏发电总量。同时,文献[15]采用聚类和混合策略实现了对太阳能电池输出功率的预测。对比集中式的大型新能源发电站,分布式新能源发电站由于考虑成本,并不会设置气象测量装置。由于缺乏预测所需要的天气预报信息,其输出信息预测难度较大。故目前针对分布式新能源发电站一般采用直接预测法。

在对已有的预测方法进行研究时发现,目前的预测方法,无论是直接预测法还是间接预测法,均旨在对分布式新能源发电站的出力进行预测。然而,为了保证分布式新能源并网的安全性和高效性,分布式新能源电站的其他信息,如发电功率、储能状态以及负载用电功率同样重要。本文提出了一种创新的分布式新能源信息预测方法,该方法融合了小波变换与神经网络技术,相比传统的 BP 传播网络以及默认的小波神经网络,能够进一步提升分布式新能源信息预测精度。通过对分布式新能源的发电功率、储能状态等信息进行详尽且准确的预测,弥补了现有针对分布式新能源预测控制的空白。从而实现分布式新能源高效并网,提升了接入分布式新能源发电后城市电网的安全性以及可靠性。

1 分布式新能源系统与建模方法

在需求侧能源资源中,风光发电资源的出力受资源环境的影响很大,所以它的出力不确定性和波动性

是亟需解决的问题^[16-17]. 在对资源高效利用的过程中,需要精确地把握风电的出力情况,使得可以高效地利用资源和稳定电网的可靠性.

通过建模分析,可以评估分布式新能源系统的最佳规模和配置,以满足能源需求,并确保能源供应的可靠性和稳定性. 这有助于制定合适的规划策略,提高能源利用效率.

1.1 光伏机组功率模型

图 1 表示了典型光伏发电机的结构. 图中 RLC 分别表示电阻负载、感性负载以及容性负载. P_{inv} 、 P_{load} 以及 ΔP 分别表示逆变器发出的有功功率、负载所需的有功功率以及从电网中获取的有功功率. 而 Q_{inv} 、 Q_{load} 以及 ΔQ 分别表示逆变器发出的无功功率、负载所需的无功功率以及从电网中获取的无功功率. 首先,光伏阵列的输出是直流电(direct current, DC). 然而,电力网和常见电气负载使用的是 50 Hz 频率的交流电(alternating current, AC). 光伏阵列所生成的直流电,需经过逆变器的转换,将其变为交流电,方可接入电网并供应给负载使用^[18]. 当光伏阵列产生的电能超过负载需求时,多余的能量会流向电网^[19]. 如果光伏阵列的电能不能满足负载需求,可以从电力系统获取电能^[20].




图 1 光伏发电结构

Fig. 1 The structure of a photovoltaic power system

光伏阵列的输出功率具有显著的非线性特征,它深受日照强度、环境温度以及天气情况等气象条件的影响^[21]. 为了充分发掘光伏阵列输出功率的最大潜力,对光伏阵列的输出功率特性进行深入研究显得尤为重要. 光伏发电机组的输出功率主要受到光照强度的影响. 研究表明,光照强度的分布近似遵循 Beta 分布. 基于这一发现,得到了相应的概率密度函数,该函数能够描述光照强度在不同取值下的概率分布情况.

$$f_{PV}(G) = \frac{\Gamma(\sigma + \theta)}{\Gamma(\sigma)\Gamma(\theta)} \left(\frac{G}{G_{\max}} \right)^{(\sigma-1)} \left(1 - \frac{G}{G_{\max}} \right)^{(\theta-1)}. \quad (1)$$

式中, G 为实际的光照强度; G_{\max} 为光照强度最大值; Γ 为伽玛函数; $f_{PV}(G)$ 表示的是光照强度为 G 下的概率密度函数; θ 和 σ 为 Beta 分布中的形状参数,其数值是由对历史光照强度数据统计分析得出的. 光伏发电的功率输出模型为:

$$P_{PV} = P_{STC} \frac{G_{ING}}{G_{STC}} [1 + k(T_c - T_r)]. \quad (2)$$

式中, G_{ING} 为辐照强度, W/m^2 ; P_{PV} 为辐照强度为 G_{ING} 时,组件的输出功率, kW ; G_{STC} 为标准测试条件(1000 W/m^2 , 25 $^{\circ}C$)下的辐照强度; P_{STC} 为标准测试条件下组件的最大输出功率, kW ; k 为功率温度系数; T_c 为光伏电池温度; T_r 为参考温度.

1.2 风电机组功率模型

图 2 为典型的双馈感应风力发电机的结构. 双馈感应发电机与传统的异步机有所不同,它可以在次同步和超同步状态下作为发电机运行,但在这些状态之间的功率流向方向不同. 在次同步运行状态下,电网侧变流器(此时充当整流器)将来自电网的 50 Hz 交流电整流为直流电. 转子侧变流器(此时充当逆变器)将直流电逆变为具有所需频率的交流电,用于励磁转子绕组. 此时,电能通过变流器从电网输送到发电机的转子.

在超同步运行状态下,转子侧变流器(此时充当整流器)将转子绕组感应出的低频交流电整流为直流电. 电网侧变流器(此时充当逆变器)将直流电逆变为与电网频率相同的交流电,并馈入电网. 此时,电能通过变流器从发电机的转子馈送到电网.

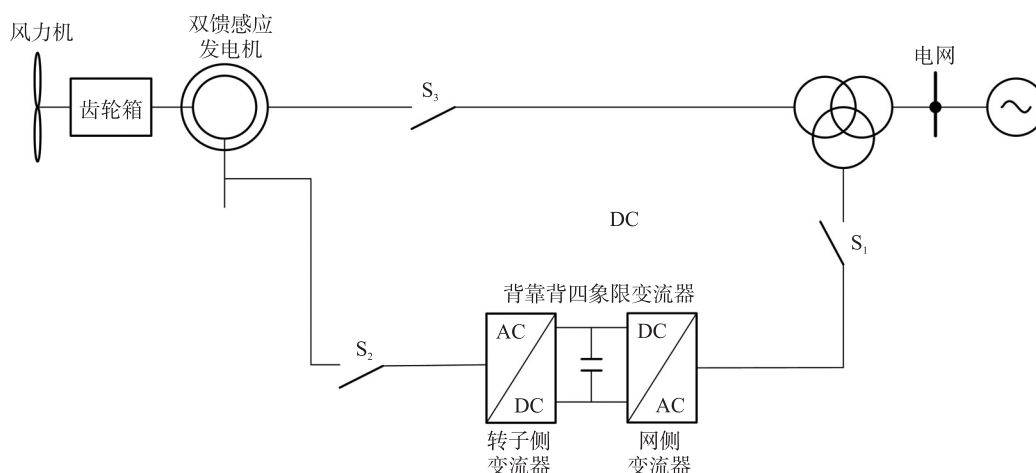


图 2 双馈感应风力发电机结构

Fig. 2 The structure of a doubly-fed induction wind power generator

在同步运行状态下,变流器为发电机提供直流电。在实践中,风力涡轮机组很少严格处于同步状态,即使在这种状态下运行,持续时间也非常短。因此,在控制方面,当发电机接近同步运行时,提供的励磁电流是具有非常低频率的交流电。

风速是影响风力发电机组输出功率的关键因素。大量的实测数据发现大多数地区的风速近似符合 Weibull 分布。该概率密度函数为,

$$f_{WT}(v) = \left(\frac{k}{c}\right) \left(\frac{v}{c}\right)^{(k-1)} \exp\left[-\left(\frac{v}{c}\right)^k\right]. \quad (3)$$

上式准确地描述了风速在不同取值下的概率分布情况。式中, $f_{WT}(v)$ 表述的是风速为 v 下的概率密度函数; v 为风机所在位置的实际风速; k 是 Weibull 分布的形状参数; c 是 Weibull 分布的尺度参数。除风速外,还有一些参数会影响风力机的输出功率。式(4)表述的是风力机的输出功率:

$$P_m = \frac{1}{2} C_p \rho A v^3. \quad (4)$$

式中, A 表示垂直于风速的面积。风力机输出功率与空气密度 ρ 、风速 v 、垂直于风速的面积 A 和风能利用系数 C_p 都有关。由风电机组当地的位置的风速,得到风电机组的输出功率,

$$P_{WT} = \begin{cases} 0, & v < v_{in}, v > v_{out}, \\ av+b, & v_{in} \leq v \leq v_r, \\ p_r, & v_r < v \leq v_{out}. \end{cases} \quad (5)$$

P 为风电机组的有功输出功率; p_r 为风电机组的额定输出功率; v_{in} 为切入风速; v_{out} 为切出风速; v_r 为额定风速; a 、 b 则是风电机组的基础参数。

由式(5)可知,当风力发电机组运行时,共会有 4 种不同状态的情况出现:当 $v < v_{in}$ 时,未达到机组启动的性能方面的需求,在此情况下,机组处于停机状态,因此无法产生任何功率输出;当 $v_{in} \leq v \leq v_r$ 时,机组输出功率与风速的变化呈现出正比关系;当 $v_r < v \leq v_{out}$ 时,机组以额定功率运行;当 $v > v_{out}$ 时,为确保机组安全性,机组已退出运行状态,无任何输出。

2 基于小波变换神经网络的信息预测模型

天气条件、地理位置和季节变化等多种因素相互耦合,造成了分布式新能源的出力特性不规律、不稳定的特点,而用户对用电功率的稳定性需求逐步提升,成为了分布式新能源系统控制策略研究的一大重点。准确预测分布式新能源信息是有效控制的基础。

2.1 小波神经网络

由于分布式新能源的出力模型中各项参数存在复杂的非线性关系,传统的线性模型往往难以准确描述这些关系,而供电需要实时调整以满足需求,准确的新能源出力预测可以帮助系统运营者更好地调度电

力资源,提高系统的稳定性和可靠性.同时,通过准确预测新能源出力,电力系统能够更有效地规划和管理电力生产,避免不必要的成本浪费.因此引入机器学习算法,实现对分布式新能源的出力特性的准确预测具有一定的必要性.

小波神经网络(wavelet neural network, WNN)结合了小波变换和神经网络的特点,能够对信号进行多尺度分析,适用于捕捉新能源出力中的短时变化和长时趋势,有助于提高预测精度.同时神经网络部分可以有效处理新能源系统中存在的非线性关系,提高模型的逼近能力. WNN 具有高适应性,能够灵活地调整模型参数以适应不同条件下的出力变化.最后, WNN 的结合还使得时频分析更为方便,有助于捕捉新能源系统中的时变特性.因此,本文采用 WNN 对分布式新能源系统的出力进行预测,为系统控制策略提供参考.

图 3 为 WNN 结构图.其中, x_1, x_2, \dots, x_n 为输入向量, y_1, \dots, y_m 为输出值,而 h_1, h_2, \dots, h_j 为母小波函数.对于输入向量,隐含层的输出为,

$$h(j) = h_j \frac{\sum_{i=1}^n \omega_{ij} x_i - b_j}{a_j}, j = 1, 2, \dots, m. \quad (6)$$

式中, $h(j)$ 为隐藏层中节点 j 的输出值, h_j 是母小波函数, w_{ij} 是连接输入层和隐藏层的权重, b_j 是平移参数,而 a_j 是 h_j 的伸缩参数.输出层的输出为,

$$y(k) = \sum_{i=1}^m \omega_{ik} h(i), k = 1, 2, \dots, l. \quad (7)$$

式中, $h(i)$ 为隐含层中节点 i 的输出值, ω_{ik} 为连接隐含层和输出层的权重, l 和 m 分别为输出层和隐含层的节点数.

在信号输入后, WNN 首先将信号分解成不同频率和时间尺度上的成分,并输入到神经网络的隐含层,对应为每个隐含层的神经元,最后通过权重学习将预测结果输出到输出层.

2.2 基于优化小波神经网络的预测模型构建方法

为使 WNN 算法精确预测分布式新能源的出力分布,需要对算法进行一定的训练,如图 4 所示.

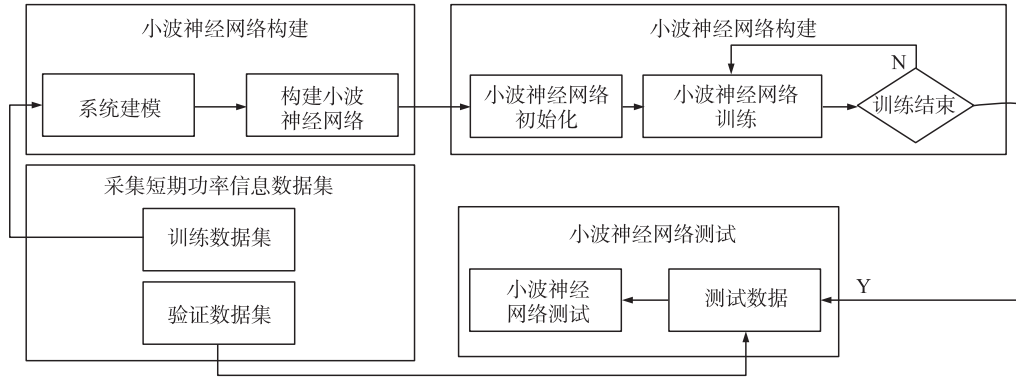


图 4 WNN 预测模型的构建方法

Fig. 4 Construction method of WNN prediction model

通过收集和整理分布式新能源系统的历史出力数据,包括太阳能光伏和风能等,并将数据分为训练集和测试集.首先,对训练集进行小波变换,实现多尺度分析,得到不同尺度上的小波系数.将这些小波系数作为神经网络的输入特征,并生成相应的目标输出.通过使用滚动时间轴的方法,以一定时间窗口内的小波系数作为输入,下一个时间点的出力作为输出.

通过设计神经网络结构,使输入层的神经元数等于小波系数的特征数,输出层的神经元数与预测的出力维度相匹配,并确定神经网络的激活函数、学习率等超参数.在神经网络结构设计完成后,对神经网络的权重进行初始化,并使用训练集进行反向传播训练.通过调整权重来使得误差最小.

最后,利用测试集评估训练好的 WNN 模型的性能,通过计算均方根误差(RMSE)等指标来评定模型的预测精度.

2.3 小波神经网络参数调节方法

为了进一步提高 WNN 的预测精确度,需要对其参数进行适当调节.然而,由于 WNN 算法的复杂性,

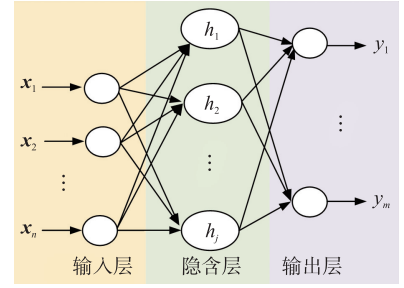


图 3 WNN 结构示意图

Fig. 3 Structure of WNN schematic

其内部包含了多个可调节参数,各个参数互相影响,使参数调节变得困难.

贝叶斯优化被广泛用于解决黑箱问题,在每一次迭代中,先验函数拟合目标函数,采集函数用于探索潜在的最优结果. 先前迭代的先验分布在获取函数中用来找到最大化的数据点. 通过评估该数据点在目标函数中的性能,得到优化结果. 获得预测数据后,建立后验分布,成为下一步迭代的先验分布. 由于贝叶斯优化考虑了之前的结果,参数优化速度更加迅速.

为了提升小波神经网络的预测精确度,采用贝叶斯算法对其中的参数进行优化. 小波基函数为

$$h_{a,b}(j) = \frac{1}{\sqrt{a}} h\left(\frac{j-b}{a}\right). \quad (8)$$

式中, $h(j)$ 为母小波函数,而 $h_{a,b}(j)$ 通过母小波函数缩放 a 倍并平移 b 倍得到,称为小波基函数,它是由母小波函数经过平移和伸缩得到的,依赖于参数 a 和 b . 其中 a 被称为伸缩参数,而 b 被称为平移参数. 为了选择合适的小波基函数,提高 WNN 的精确度,需要对 WNN 中的平移参数和伸缩参数进行适当的调整. 本例中,使平移参数 b 的变化范围为 $1 \sim 5$,伸缩参数 a 的变化范围为 $1 \sim 500$. 以最小化均方误差(MSE)作为优化目标. MSE 的计算公式为,

$$\text{MSE} = \frac{1}{m} \sum_{i=1}^m (p_i - p_{i-\text{predict}})^2. \quad (9)$$

式中, m 为总预测样本数, p_i 为第 i 个真实值,而 $p_{i-\text{predict}}$ 为第 i 个预测值.

以某日的光伏辐照特性分布的预测为例,经过贝叶斯算法优化后的结果显示,在调节至最佳参数的情况下,WNN 预测模型成功将 MSE 从 0.045 降低到 0.01,降低了 77%. 相比使用默认参数的 WNN 预测模型,提高了精确度.

3 分布式新能源信息预测模型仿真验证

本文基于某地区 4 月以及 10 月的总风电数据,利用不同的机器学习算法验证了所提出的预测方法的准确性. 将使用每天测量的风电曲线作为测试数据,将优化的贝叶斯优化的 WNN 的准确性与具有默认参数的 WNN 进行比较,同时引入反向传播神经网络作为对比.

图 5(a)~图 5(d)分别为该地区 4 月 5 日、10 日、15 日和 20 日不同方法下的风电功率曲线. 图中实线为实际测量值,点横虚线为 BP 神经网络的预测值,短横虚线为默认的 WNN 的预测值,而点虚线为优化后的 WNN 的预测值. 可以看到,3 种方法的预测曲线在大致趋势上都与实际上的测量值一致. 但是 BP 神经

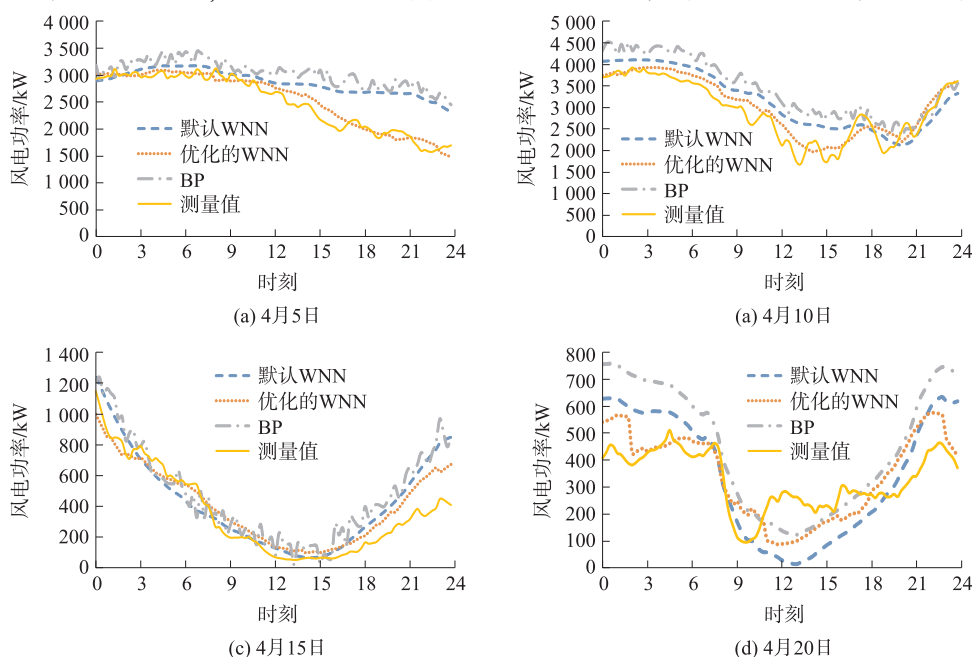


图 5 不同方法下不同日期风电预测的比较(4 月)

Fig. 5 Comparison of wind power predictions for different dates under different methods(in April)

网络的预测值波动较大,并且与实际测量值的误差也较大.采用 WNN 方法后,预测值波动较小,其中优化后的 WNN 方法比默认的 WNN 方法更加接近实际测量值.并且当实际风电功率有较大波动或者在短时间快速变化时,能实现更好的跟随效果.

图 6(a)~图 6(d)分别为该地区 10 月 5 日、10 日、15 日和 20 日下不同方法下的风电功率曲线.与图 5 所呈现出来的情况一致.优化的 WNN 具有最佳的预测准确性,而具有默认参数的 WNN 次之,BP 神经网络具有最低的预测准确性.当风电变化趋势较小时,如 10 月 5 日,3 种预测算法的预测准确性接近.当风电变化趋势较大或在短时间内快速变化时,如 10 月 20 日,优化的 WNN 算法具有更明显的优势,并能紧密跟随实际风电值.

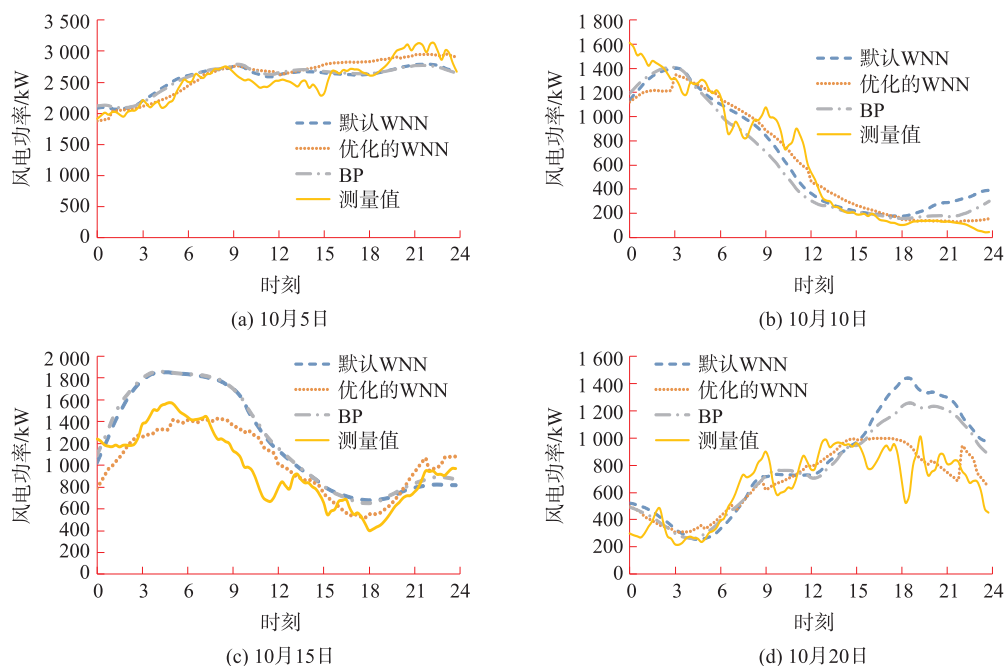


图 6 不同方法下不同日期风电预测的比较(10 月)

Fig. 6 Comparison of wind power predictions for different dates under different methods(in October)

图 7 表示的是 4 月份和 10 月份每日预测结果均方根误差值的比较.如图 7 所示,优化的 WNN 在 4 月份以及 10 月份每一天其均方根误差值都是最小的,而 BP 神经网络其均方根误差值是最大的,默认的 WNN 其均方根误差值介于两者之间,但更靠近 BP 神经网络.这意味着优化的 WNN 整体上具有更好的准确性,而默认的 WNN 的准确性略好于 BP 神经网络的准确性,但提升不大,整体上比较接近.由于前文所述因素的影响,当风电快速变化时,3 种算法的准确性都会不同程度地降低.

图 8(a)和图 8(b)分别表示季度与年度下的平均均方根误差值比较.如图 8(a)所示,在季度平均误差率方面,默认 WNN 的误差率略微低于 BP 神经网络,幅度很小,而优化的 WNN 的误差率大幅降低.优化的 WNN 的误差率在所有季度中最低,其误差率在第三季度最低.如图 8(b)所示,优化的 WNN 的年平均误差率比 BP 神经网络低 19.9%,比默认 WNN 低 9.5%.

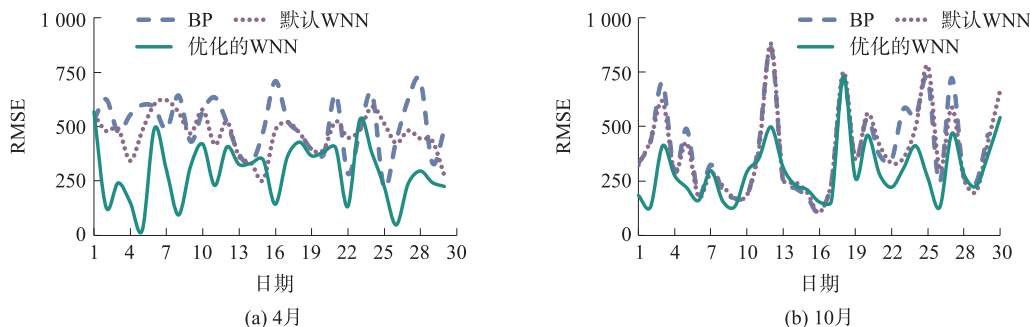


图 7 每日预测结果 RMSE 值比较(4 月、10 月)

Fig. 7 Comparison of RMSE values for daily forecast results(in April and October)




图 8 平均均方根误差值比较

Fig. 8 Comparison of quarterly average RMSE

表 1 为不同风力发电水平下均方根误差值比较,分别设置了发电量小于 1 000 kW,发电量在 1 000 kW 和 2 000 kW 之间以及发电量大于 2 000 kW 共 3 个等级. 如图所示,在共 3 个发电等级下,优化的 WNN 误差率均为最小,默认 WNN 次之,最后则是 BP 神经网络. 随着风力发电水平的提高,优化的 WNN 的误差率逐渐降低,并且相比于 BP 神经网络和默认 WNN,在不同发电水平下,其预测准确性得到了极大的改善.

表 1 不同风力发电水平下 RMSE 值比较

Table 1 Comparison of RMSE values at different wind power generation levels

发电水平/kW	RMSE		
	BP	默认 WNN	优化的 WNN
<1 000	401.14	396.80	340.68
1 000~2 000	420.12	406.25	318.59
>2 000	398.90	387.75	307.10

考虑到风力受气候和其他因素的影响,具有极端不稳定性的特点,本文提出的基于优化的 WNN 算法的分布式新能源信息预测方法也将对系统内其他类型的信息具有高预测准确性,并且这种方法具有良好的泛化能力.

4 结论

考虑到气候和各种外部因素对风力动态的多方面影响,再加上其固有的波动性,以风力发电为代表的新能源发电功率的高精度预测具有重要的研究价值. 在这种背景下,本文提出了基于优化 WNN 算法的分布式新能源信息预测方法. 与传统方法相比,本文提出的预测方法实现了对风力发电功率更准确的预测,这对于优化新能源发电的运营和管理,最大限度地提高新能源的分配效率,避免能源浪费具有重要意义. 通过更高精度地预测未来的新能源发电功率,电网集成和储能的调度可以得到优化,有助于相关部门制定更科学的并网控制策略,提高电网整体的弹性和稳定性. 同时,对新能源发电功率更高效的应用也避免了能源的浪费,降低了对化石能源的浪费,促进了绿色电力市场的发展.

(1)使用贝叶斯超参数优化算法优化了 WNN 的参数,并且优化后的 WNN 具有适应性和能够根据贝叶斯优化算法调整参数的能力,在捕捉风电动力学差异的复杂性和微妙性方面具有显著优势. 通过受概率原理指导的迭代调整,贝叶斯优化的 WNN 能够有效地预测复杂的风电数据,从而提高了其预测准确性和稳健性.

(2)通过在不同条件和情景下对比贝叶斯优化后的 WNN、默认 WNN 和 BP 神经网络的预测准确性,全面评估了它们的预测准确性. 这些发现强调了贝叶斯优化后的 WNN 在捕捉风电水平的微妙和快速变化方面的优越性能. 这种改进的准确性可以归因于该算法的适应性和贝叶斯优化框架,使其能够有效地识别数据集中的模式和趋势. 此外,季度和年度误差率分析提供了另一个用于比较预测准确性验证的方面,揭示了随着时间推移不同的模式和趋势. 优化的 WNN 在各个方面的一致优势表明其稳健性和可靠性,使其成为更适用的预测算法.

(3)本研究的综合分析阐明了优化小波变换神经网络在预测风力发电方面的有效性,展示了贝叶斯优化 WNN 在此方面的优点.

[参考文献](References)

[1] 朱广岩,张小妹,严晓辉,等. 中国现代能源体系建设进程评估研究[J]. 工程科学与技术,2024,56(1):206-217.

- [2] 林雨眠,熊厚博,张笑演,等. 计及新能源机会约束与虚拟储能电-热系统分布式多目标优化调度[J/OL]. 电工技术学报:1-19[2024-04-10]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.230926>.
- [3] 郭佩乾,郝峰杰,袁志昌,等.混合多类型储能的分布式能源系统运行优化方法[J/OL]. 南方电网技术:1-11[2024-04-10]. <http://kns.cnki.net/kcms/detail/44.1643.TK.20230913.2328.008.html>.
- [4] 陆溪. 新能源技术的分布式电源在电网中的应用[J]. 中国高科技,2023(17):110-112.
- [5] 穆璇,吴青龙,邹瞳.“十三五”以来中国能源消费研究现状与热点分析[J]. 中北大学学报(社会科学版),2023,39(4):70-76.
- [6] 谭宇航,肖天伦,杨保亮. 风电负荷分布式系统无聚类随机优化调度[J]. 控制工程,2022,29(11):2066-2074.
- [7] 侯伟,肖健,牛利勇. 基于灰色理论的光伏发电系统出力预测方法[J]. 电气技术,2016(4):53-58.
- [8] 李光明,刘祖明,何京鸿,等. 基于多元线性回归模型的并网光伏发电系统发电量预测研究[J]. 现代电力,2011,28(2):43-48.
- [9] WANG Y R, WANG D C, TANG Y. Clustered hybrid wind power prediction model based on ARMA, PSO-SVM and clustering methods[J]. IEEE Access, 2020, 8:1-8.
- [10] 项晓宇,朱敏捷,周灵刚,等. 基于机器学习的短期规上行业工业增加值预测[J]. 南京师大学报(自然科学版),2023,46(2):99-106.
- [11] 张惠娟,刘琪,岑泽尧,等. 基于 GWO-MLP 的光伏系统输出功率短期预测模型[J]. 电测与仪表,2022,59(7):72-77,113.
- [12] WU Y H, LIU J B, ZHANG J A, et al. Short-term forecast of photovoltaic power generation output based on improved PSO-Elman neural network[J]. IOP Conference Series:Earth and Environmental Science, 2021, 675(1):3-7.
- [13] 王粟,隗磊锋,曾亮. 基于 GWO-SVM 与随机森林的组合光伏功率预测模型[J]. 昆明理工大学学报(自然科学版), 2021, 46(5):82-88.
- [14] PIERRO M, DE FELICE M, MAGGIONI E, et al. Data-driven upscaling methods for regional photovoltaic power estimation and forecast using satellite and numerical weather prediction data[J]. Solar Energy, 2017, 158:1026-1038.
- [15] ZHANG X, LI Y, LU S, et al. A solar time based analog ensemble method for regional solar power forecasting[J]. IEEE Transactions on Sustainable Energy, 2019, 10(1):268-279.
- [16] CABAN J, MALEK A, ŠARKAN B. Strategic model for charging a fleet of electric vehicles with energy from renewable energy sources[J]. Energies, 2024, 17(5):1264.
- [17] LEE S, LEE E, LEE J, et al. Strategy for enhancing hosting capacity of distribution lines using a vertical photovoltaic system[J]. Energies, 2024, 17(6):1390.
- [18] 薛雯,闵富红,步娇娇,等. 流控型 Buck 变换器的动力学行为分析[J]. 南京师范大学学报(工程技术版), 2024, 24(1):32-39.
- [19] MA D, XIE R, PAN G, et al. Photovoltaic power output prediction based on tabnet for regional distributed photovoltaic stations group[J]. Energies, 2023, 16(15):5649.
- [20] ANASTASIADIS A G, PAPADIMITRIOU P, VLACHOU P, et al. Management of hybrid wind and photovoltaic system electrolyzer for green hydrogen production and storage in the presence of a small fleet of hydrogen vehicles: An economic assessment[J]. Energies, 2023, 16(24):7990.
- [21] CHEN C S, TSAI C T, LIN C H, et al. Loading balance of distribution feeders with loop power controllers considering photovoltaic generation[J]. IEEE Transactions on Power Systems, 2011, 26(3):1762-1768.

[责任编辑:陈 庆]