

DOI: 10.12158/j.2096-3203.2023.06.025

基于多目标协同训练的风电功率预测提升算法

宋家康¹, 赵建勇², 孙海霞¹, 王华雷¹, 年珩², 张森²(1. 国网江苏省电力有限公司连云港供电分公司, 江苏 连云港 222000;
2. 浙江大学电气工程学院, 浙江 杭州 310027)

摘要:“双碳”目标下,电力系统加速转型,风电预测技术对构建高比例新能源的新型电力系统具有重要意义。为提升风电功率预测的准确性和鲁棒性,文中提出一种基于多目标协同训练的数值天气预报(numerical weather prediction, NWP)隐式校正算法。首先,分析了NWP校正的必要性和基于NWP显式校正的二步预测法存在的问题;然后,针对二步预测法存在的问题,基于多目标协同训练的优化方式利用神经网络进行NWP隐式校正,以端到端的方式训练模型,同时实现NWP隐式校正和风电功率预测的功能。结合某风电场实测数据开展具体算例分析,证明了所提算法对短期及中长期风电功率预测均有提升作用。此外,该算法仅需1个网络且避免了二次计算,节省了计算存储成本。

关键词:风电功率预测;数值天气预报(NWP)隐式校正;神经网络;提升算法;多目标协同训练;二步预测法
中图分类号:TM641 **文献标志码:**A **文章编号:**2096-3203(2023)06-0232-09

0 引言

随着新能源的迅速发展,如何建设新型电力系统,实现高比例新能源并网已经成为研究热点,同时这也是实现双碳战略目标的必经路径^[1-2]。既定政策情境下,主要能源市场的新政策有望在2030年前将年度清洁能源投资提高到2万亿美元以上。风电当前在新能源中占比最高,同时也是未来新能源的主体。但随着风电装机容量的不断增加,新的风电问题不断产生^[3],亟须研究更高精度的风电功率预测技术。

风电功率预测一般分为超短期预测、短期预测和中长期预测^[4]。目前,短期、超短期风电功率预测的相关研究已相对成熟,其预测结果已可以基本满足国家能源局的要求^[5]。研究难点也因此逐渐从短期、超短期预测转为中长期预测,且主要基于智能学习方法进行改进优化^[6]。智能学习方法主要以数值天气预报(numerical weather prediction, NWP)数据及相关历史数据为输入,以机器学习模型为主网络进行建模^[7]。根据文献[8],大气运动过程是历史和当前状态共同作用的结果。这表明随着预测时长的增加,智能学习模型主要输入NWP的预测误差将随时间累积,从而导致预测模型的精度显著下降,其中中长期风电功率预测尤为明显。

因此,为提升风电功率预测精度,文献[9]阐述了利用实测气象数据对NWP进行校正,以此提升短期风电功率预测精度的方法,但其未进行中长期

风电功率预测分析,文中将其称为二步预测法;文献[10-14]提出基于长短期记忆网络和随机森林的组合预测方法,在天气突变情况下仍能保持较高的预测精度;文献[15]基于高层NWP气象数据,根据高层NWP气象数据的演变物理模型,集合统计分析和物理模型,有效提高了中长期风电功率预测精度。上述方法从不同层面提升了风电功率预测精度,但算法均涉及多个模型,较为复杂,可适用性不强。文中基于多目标协同训练的优化方式利用神经网络(neural network, NN)进行NWP隐式校正,在节省计算存储成本的同时,提升了短期及中长期风电功率预测的精度,具有较强的适应性。

文献[9, 16-17]的研究表明,基于NWP显式校正的二步预测法并不稳定,在某些时候并不能提升风电功率预测精度。因此,文中首先对二步预测法无法提升精度的情况进行了分析与探讨;随后,针对NWP显式校正的问题,提出NWP隐式校正算法,主要思路是以实测风电功率为最终输出、实测气象数据为隐层输出,通过多目标损失函数协同训练网络,使得模型同时具备风电功率预测和气象预测能力。最后,以国内某实际风电场为对象进行算例分析,通过横向指标和纵向指标对比分析了NWP显式校正、隐式校正及主流智能学习模型的优劣,验证了所提算法的有效性和优越性。

1 二步预测法

1.1 算法原理

二步预测法^[16]采用2个模型分别进行NWP显

收稿日期:2023-05-25;修回日期:2023-07-29

基金项目:国家自然科学基金资助项目(51977194)

式校正和风电功率预测。在训练时,首先以 NWP 数据为输入,以实测气象数据为输出,基于机器学习模型建模优化,得到 NWP 显式校正模型;然后以实测气象数据为输入,以实测风电功率数据为输出,基于机器学习模型建模优化,得到风电功率预测模型。在推理时,首先将原始 NWP 数据作为 NWP 显式校正模型的输入得到 NWP 校正结果;然后将 NWP 校正结果作为风电功率预测模型的输入,得到最终的风电功率预测结果,其流程如图 1 所示。

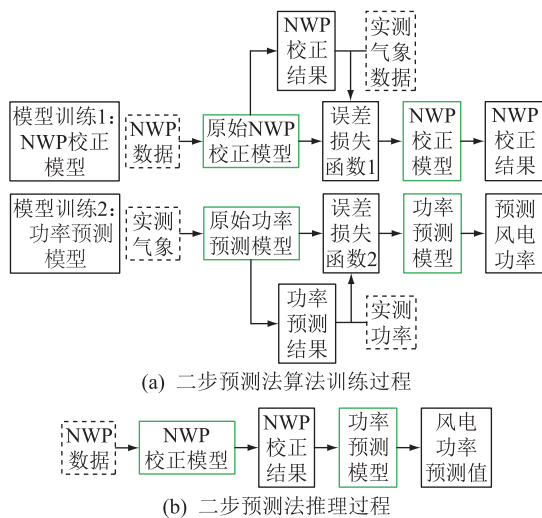


图 1 二步预测法

Fig.1 Two-step prediction method

NWP 数据包含多项气象特征,如风速、温度、湿度等。因此,NWP 显式校正模型须采用具有多输出能力的网络,如神经网络或随机森林;也可以采用多个单输出模型并行输出,如采用多个梯度提升决策树 (gradient boosting decision tree, GBDT) 模型并行输出,但这会进一步增加网络的数量。根据风电功率的计算公式^[10],风速、温度、湿度、压强是风电功率预测最重要的典型特征,而根据文献[6],引入上述特征之外的非典型特征对提高风电功率预测精度同样有作用。因此,采用单输出模型进行 NWP 显示校正至少需要 4 个网络。

1.2 误差分析

由 1.1 节所述算法原理可知,基于 NWP 显式校正的二步预测法的误差主要有两部分。第一部分是第二步风电功率预测模型本身固有的预测误差;第二部分则是第一步 NWP 显式校正误差输入第二步功率预测模型后传递的误差。整体误差的表达如式(1)所示。

$$E = f_2(E_{s1}) + E_{s2} \quad (1)$$

式中: $f_2(\cdot)$ 为第二步风电功率预测模型表示的函

数; E_{s1} 、 E_{s2} 分别为第一步的 NWP 显式校正误差及第二步的风电功率预测固有误差。

虽然二步预测法引入了额外的误差项 $f_2(E_{s1})$,但是第二步的预测误差 E_{s2} 要比常规模型的预测误差小得多,因为其功率预测模型是通过实测气象及功率数据进行拟合的模型。因此,二步预测法相对于不进行 NWP 校正的预测模型所能带来的误差改善可被表示如式(2)所示。

$$\Delta E = E_r - (f_2(E_{s1}) + E_{s2}) = (E_r - E_{s2}) - f_2(E_{s1}) \quad (2)$$

式中: E_r 为不进行 NWP 校正的预测误差,即直接采用 NWP 数据及实测风电功率数据进行建模的预测误差。

根据式(2),当 NWP 显式校正引入的额外误差 $f_2(E_{s1})$ 小于功率预测模型带来的误差改善 $E_r - E_{s2}$ 时,二步预测法将最终决定风电功率的预测精度。但是,当 NWP 显式校正引入的误差大于功率预测模型带来的误差改善时,二步预测法将会失效,甚至显著降低预测精度。

因此,文中将神经网络的隐含层输出作为 NWP 的隐式校正结果,并将隐式校正结果输入后续隐含层最终输出功率。通过多目标协同训练的方式进行模型优化,相当于同时对 $f_2(E_{s1})$ 和 E_{s2} 误差项进行优化,进而避免二步预测法失效风险。

2 隐式校正

2.1 神经网络 (NN)

NN 是一种由神经元组成、模仿动物神经网络行为特征的网络。NN 本质上可视为一个复杂非线性函数,复杂程度受网络隐含层数量及每层的神经元数量影响。一个 m 维输入 n 维输出的 3 层神经网络的结构如图 2 所示。




图 2 3 层神经网络结构

Fig.2 Structure of 3-layer neural network

根据文献[18],NN 不需要通过复杂的公式推导来求解网络的解析表达式,而是基于随机梯度下降 (stochastic gradient descent, SGD) 优化算法来求得

网络参数的近似最优解。SGD 算法的基础是参数的梯度,也就是目标损失函数关于参数的偏导数,一般采用误差反向传播(back propagation, BP)算法进行求解^[19-21]。因此,采用 BP 算法进行梯度求解的前向神经网络被称为 BP 神经网络。设目标的损失函数如式(3)所示。

$$L(W, b) = \frac{1}{N} \sum_i f_{\text{loss}}(y_{\text{pred},i}, y_{\text{real},i}) \quad (3)$$

式中: W 为该次迭代的梯度; b 为该次迭代的权重; N 为训练样本的数目; $f_{\text{loss}}(\cdot)$ 代表单条或一组数据的损失函数; $y_{\text{pred},i}$ 、 $y_{\text{real},i}$ 分别为*i*时刻预测样本和实际样本。SGD 算法的更新如式(4)所示。

$$\begin{cases} W_{t+1} = W_t - \frac{\partial L(W, b)}{\partial W_t} \\ b_{t+1} = b_t - \frac{\partial L(W, b)}{\partial b_t} \end{cases} \quad (4)$$

式中: W_t 为*t*次迭代的梯度; b_t 为*t*次迭代的权重。

由上述公式可知,NN 的训练本质上是获取一组最小化训练数据损失函数值的网络参数的过程。目标损失函数确定了网络优化的目标,梯度决定了参数优化的方向。

2.2 隐式校正

根据 NN 的结构组成及 SGD 算法的优化思路,文中设计了图 3 的神经网络结果,旨在通过 SGD 算法将二步预测法中 NWP 显式校正引入的额外误差进行优化消除。

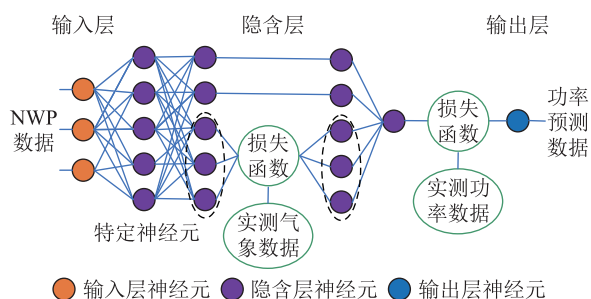


图 3 基于 NN 的预测网络设计

Fig.3 Predictive network design based on NN

由图 3 可知,所设计的网络主体为多层的前向神经网络。首先在输入层输入 NWP 数据,输入层的神经元数量便等于 NWP 气象特征的数量。随后,中间隐含层通过非线性激活函数及嵌套运算对 NWP 数据进行特征提取,旨在挖掘输出层与输入层的复杂关系。与 NWP 显式校正不同,文中所设计的网络选取了中间某一隐含层的特定神经元输出作为实测气象的预测,而输出层作为实测功率的预测。一方面,所选取隐含层输出的 NWP 校正结果与实测气象的误差将输入损失函数参与 SGD 优化;

另一方面,所选取隐含层输出的 NWP 校正结果将输入后续的隐含层参与后续的特征提取。也就是说,所设计网络在进行 SGD 优化时,损失函数不仅涉及风电功率项,还同时存在实测气象特征等多项目标。这意味着,网络在优化训练时,不仅优化了风电功率及实测气象对应 NWP 输入的误差,还同时优化了风电功率对应隐含层输出 NWP 校正结果的误差。

所设计的算法仅需要 1 个网络,通过多目标协同训练、隐含层校正 NWP 的方式同时实现了二步预测法的 NWP 显式校正和风电功率预测。同时,还优化了二步预测可见法中 NWP 显式校正引入的额外误差。因为 NWP 校正结果为隐含层输出,又采用了多目标协同训练的方式,所以将所设计算法称为基于多目标协同训练的 NWP 隐式校正算法,与 NWP 显式校正相对应。整体的算法原理如图 4 所示。




图 4 基于多目标协同训练的 NWP 隐式校正算法原理
Fig.4 Principle of NWP implicit correction algorithm based on multi-objective collaborative training

在模型训练时,NWP 数据作为模型的输入,模型同时输出风电功率预测结果及气象预测结果,联合实测风电功率数据及实测气象数据训练模型。而在推理时,NWP 数据输入模型得到功率预测及气象预测结果,但最终只取风电功率预测结果作为模型输出。即气象目标只是协同训练,帮助模型更好的迭代、调整权重,以获得精度更高的风电功率预测结果。

2.3 损失函数设计

根据文献[22],功率预测模型本质上是一种回归模型,即挖掘实测功率与 NWP 数据的回归关系。回归任务通常选择均方误差函数,其表达式为:

$$f_{\text{MSE}}(y_{\text{pred},i}, y_{\text{real},i}) = y_{\text{pred},i} - y_{\text{real},i} \quad (5)$$

由 2.1 节分析可得,SGD 优化的基础便是梯度,即通过目标损失函数对参数的梯度来更新参数。因此,目标损失函数的导数曲线更能直观地反映网络对于不同程度误差的惩罚程度。因此,以误差作为横坐标,损失值作为纵坐标,可得均方根误差函数及其导数曲线如图 5 所示。




图5 均方根误差函数及其导数曲线

Fig.5 Root mean square error function and its derivative curve

由图5可知,只有预测值和真实值相同时,误差值及其导数才为零;而当误差存在时,误差导数随误差呈线性增长趋势,即误差越大,梯度越大。文中所设计的网络同时预测风电功率和实测气象数据,因此,总体损失函数由风电功率预测误差和实测气象预测误差两部分构成,如式(6)所示。

$$L = \frac{1}{n} \sum_{i=1}^n \left(\frac{P_{\text{pred},i} - P_{\text{real},i}}{C_i} \right) + \beta \sum_{i=1}^n \left(\frac{W_{\text{pred},i} - W_{\text{real},i}}{C_i} \right) \quad (6)$$

式中: $P_{\text{pred},i}$ 、 $P_{\text{real},i}$ 分别为*i*时刻的预测风电功率和实测风电功率; $W_{\text{pred},i}$ 、 $W_{\text{real},i}$ 分别为*i*时刻的预测气象和实测气象; n 为总时刻; C_i 为*i*时刻的开机容量,用于归一化数据; β 为权重系数,用于调节两者权重,此处取0.5。

3 算例分析


文中选取国内某风电场作为实际算例进行仿真分析。该风电场装机容量为99 MW,配套数据包含:2020年采样间隔为15 min数据的实测出力数据、实测气象数据、NWP数据,其中NWP数据为每日更新的未来7 d预测数据。文中以2020年1月—2020年8月的数据作为训练集,2020年9月—2020年10月的数据作为测试集进行算例分析。

3.1 数据分析


图6分别给出了7个预测日下风电功率数据与NWP预测风速数据的相关性以及实测风速数据与NWP预测风速数据的均方根误差。

3.2 评价指标

根据文献[23-24],误差分为纵向误差和横向误差两大类,分别从宏观角度和时间角度描述预测的性能。文中采用常用的纵向指标均方根误差(root mean squared error, RMSE)和常用的横向指标相关系数(correlation coefficient, CC)对预测结果进行评价,具体计算如式(7)和式(8)所示。



(a) NWP数据皮尔逊系数随预测天数的变化曲线



(b) NWP数据均方根误差随预测天数的变化曲线

图6 NWP数据相关性及其误差变化

Fig.6 Correlation and error change plot of NWP data

$$E_{CC} = \frac{D(\hat{p}, p)}{\delta(\hat{p})\delta(p)} \quad (7)$$

$$E_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N \left(\frac{\hat{p}_i - p}{C_i} \right)^2} \quad (8)$$

式中: N 为样本数量; \hat{p}_i 、 p_i 分别为第*i*时刻的预测值和实际值; $D(\hat{p}, p)$ 为二者协方差; $\delta(\hat{p})$ 、 $\delta(p)$ 分别为二者的标准差。

3.3 实验对比

3.3.1 功率预测结果对比

根据已有数据建立并对比分析了不同的预测模型。参考文献[25-27],以NWP数据为输入,实测功率为输出,分别基于支持向量回归模型(support vector regression, SVR)、梯度提升决策树(gradient boosting decision tree, GBDT)和NN模型建立常用的功率预测模型,该类模型不考虑NWP校正问题,直接基于NWP数据和实测出力进行端到端训练,分别称为SVR模型、GBDT模型和NN模型;参考文献[28-29],分别基于GBDT和NN模型使用二步预测法,即先进行NWP显式校正再进行风电功率预测,将其分别称为GBDT-T模型和NN-T模型;最后,建立基于多目标协同训练的NWP隐式校正模型,因其是一种虚拟校正模型,所以将其称为NN-V模型。上述共计6类模型。

为了公平对比,基于NN网络的模型均采用5层隐含层神经网络,隐含层的神经元数量分别为100、50、40、20、10。输入层为NWP数据和构造的时间特征,共计38维特征。对二步预测法而言,拟合轮毂高处风速、气温、气压以及相对湿度共计4项

输出特征。而对所提算法,将第3层隐含层的最后4个神经元输出作为实测气象的预测输出。激活函数采用 ReLU 函数和 Sigmoid 函数的搭配,采用 Adam 算法进行优化,初始学习率设为 0.000 1,采用早停法进行训练。

由于 NWP 数据提供了未来 7 个预测日,且每个预测日均进行更新,因此本位对每个预测日均建立对应模型,实现不同时间尺度的功率预测。即对每个预测日分别建立上述 6 类模型,可得不同预测日不同模型的 RMSE 指标、CC 指标见表 1 和表 2。

表 1 不同预测日不同模型的测试集 RMSE 指标结果

Table 1 Test set RMSE indicator results for different models on different forecast days

模型	1	2	3	4	5	6	7	平均
NN-V	0.148	0.176	0.172	0.163	0.176	0.203	0.226	0.158
NN	0.162	0.183	0.183	0.178	0.195	0.212	0.234	0.168
NN-T	0.161	0.192	0.185	0.176	0.182	0.218	0.235	0.169
GBDT	0.155	0.186	0.183	0.183	0.194	0.215	0.240	0.170
GBDT-T	0.161	0.176	0.173	0.171	0.178	0.206	0.235	0.162
SVR	0.172	0.221	0.212	0.214	0.214	0.255	0.267	0.194

表 2 不同预测日不同模型的测试集 CC 指标结果

Table 2 Test set CC indicator results for different models for different forecast days

模型	1	2	3	4	5	6	7	平均
NN-V	0.817	0.737	0.743	0.763	0.711	0.570	0.499	0.605
NN	0.771	0.698	0.687	0.729	0.645	0.517	0.376	0.553
NN-T	0.783	0.723	0.687	0.722	0.689	0.530	0.364	0.562
GBDT	0.795	0.729	0.693	0.708	0.668	0.519	0.350	0.558
GBDT-T	0.766	0.732	0.730	0.734	0.707	0.555	0.380	0.575
SVR	0.743	0.648	0.613	0.567	0.542	0.311	0.221	0.456

对比所提 NN-V 模型与其余模型发现,NN-V 模型的 RMSE 指标只在第 2 个预测日为次优,其余预测日均为最优。其 CC 指标在所有预测日均明显优于其余模型,效果最为稳定,精度最高。其中,NN-V 模型相对于 NN 模型平均优化 RMSE 指标 1.02%,CC 指标 5.21%。这充分说明了所提算法对提升风电功率预测精度的有效性和优越性。

同时,为进一步说明算法的优越性,表 3 给出了各个模型采用的网络数量。

表 3 不同模型采用的网络数量

Table 3 The number of networks adopted by different models

模型	网络数量	模型	网络数量
NN-V	1	GBDT	1
NN	1	GBDT-T	5
NN-T	2	SVR	1

由表 3 可得,GBDT-T 模型虽然效果较好,但至少需要 5 个不同的 GBDT 网络来实现不同气象特征及风电功率的预测,且模型数量随气象特征的增多线性增长。而所提算法 NN-V 模型仅需 1 个神经网络便可同时进行 NWP 隐式校正和风电功率预测,同时还改善了预测性能,节省了计算存储成本,更加简便快捷。

图 7 给出第 1、3 个预测日(属于短期预测)及第 5、7 个预测日(属于中长期预测)的误差概率密度对比。

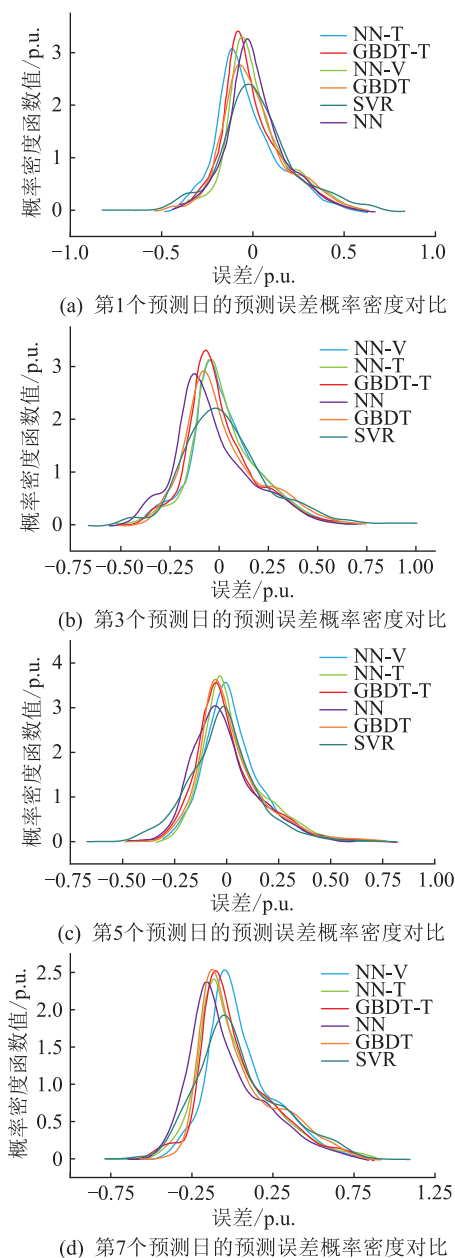


图 7 4 个预测日的预测误差概率密度对比
Fig.7 Comparison plot of prediction error probability density for 4 forecast days

由图 7 可知,文中涉及到的 6 类模型的预测误差呈现不同程度的右偏态分布。SVR 模型的偏度

最低,但峰度过大,整体误差最高。而 NN-V 模型的偏度次低,右偏程度最弱,同时峰度也较小,整体误差最低。这也说明了所提算法在短期风电功率预测(1~3 d)和中长期风电功率预测(3 d 以上)的误差分布均为最优,和表格分析结果一致,证明了所提算法的有效性和优越性。

3.3.2 隐式-显式校正结果对比

为了辅助说明所提算法的有效性,将 NWP 隐式校正结果与显式校正结果进行对比。图 8 给出了 4 类气象特征随不同预测日的预测误差曲线变化,其结果见表 4。图 9 给出了 4 项气象特征第 1 个预测日的一段校正结果对比曲线,采样间隔为 15 min。

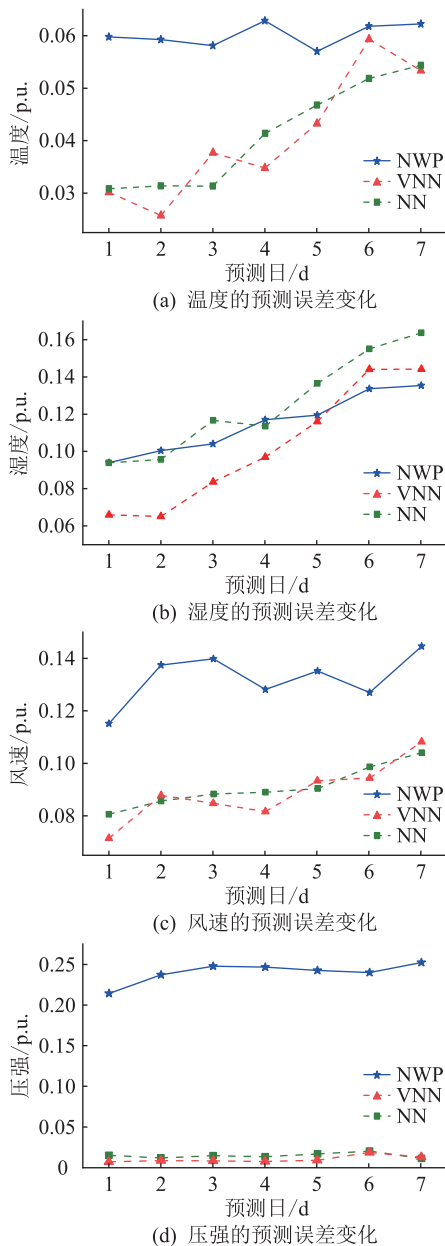


图 8 4 项气象特征的预测误差变化

Fig.8 Chart of forecast error changes for four different meteorological characteristics

表 4 4 项指标 7 d 的均方根误差结果

Table 4 Seven-day square error results for four indicators

模型	风速	温度	湿度	压强	平均
NWP	0.132 4	0.060 2	0.114 7	0.240 1	0.136 8
NN	0.089 2	0.041 4	0.102 7	0.011 9	0.061 3
VNN	0.091 0	0.040 6	0.125 0	0.015 1	0.067 9




图 9 第 1 个预测日 4 项气象特征的校正结果对比

Fig.9 Comparison of correction results for four meteorological features on the first forecast day

由图 9 可知,原始 NWP 预测数据和实测气象数据存在明显偏差,尤其对气压这一特征。NWP 数据中给出的气压特征代表的是海平面气压,而实测气象数据给出的气压特征代表的则是风电场本地测量的空气气压,因而存在明显差别。要建立合理

且鲁棒的风电功率模型,则应该采用风电场本地的气压、温度、湿度及风速等配套特征。同时,各项气象因素的误差随着预测时长呈增大趋势,这也说明进行 NWP 校正是必要的。

由表 4 可知,校正后的 NWP 指标相对原始 NWP 数据有明显的改善。通过对比发现,NWP 隐式校正结果要比显式校正结果差一些。这是因为,在网络的优化过程中,隐式校正结果对应的损失函数只占总体损失函数的一部分,此外还有输出层的损失函数值。即 NWP 隐式校正是为了让隐含层神经元在进行特征提取时能够捕捉到实测气象的特征,并将二步预测法带来的显式校正误差优化减弱,而不是为了得到精准的 NWP 显式校正结果。

由图 9 可知,校正结果最好的为气温,因为气温变化缓慢,且具有明显周期性;校正结果最差的是压强,因为压强只能依赖海平面气压去进行预测,而非本地实测气压。对所有气象特征而言,在一些突变时段,显式校正结果仍然存在明显误差。可见,NWP 显式校正也只能捕捉到实测气象的变化趋势,无法准确跟随曲线的变化,这也是二步预测法需要解决的问题。

4 结论

为解决传统 NWP 显式校正算法对于提升风电功率预测精度的不稳定性,文中首先分析了二步预测法存在的问题并进行研究;随后提出基于多目标协同训练的 NWP 隐式校正算法来提升风电功率预测的准确性和鲁棒性。该方法通过端到端的训练方式,在优化模型的同时完成了 NWP 隐式校正和风电功率预测,并提升了预测精度。通过算例分析得出如下结论:

(1) 随着预测时长增加,预测精度下降,进行 NWP 校正可改善预测性能;

(2) 基于多目标协同训练的 NWP 隐式校正算法仅需 1 个网络、并提升了风电功率预测精度,效果最为稳定,其短期及中长期的预测结果的 RMSE 指标、CC 指标均最优。根据算例分析,文中提出的模型相对于普通基于神经网络的预测模型平均优化 RMSE 指标 1.02%、CC 指标 5.21%。

此外,文中所提算法容易实现,在现有 NN 模型基础上进行轻微修改便可应用,具有较强的可拓展性。

致 谢

本文得到国网江苏省电力有限公司连云港供电公司科技项目(B710D02229KD)、浙江省教育厅

科研项目(Y202250621)资助,谨此致谢!

参考文献:

- [1] 张智刚,康重庆. 碳中和目标下构建新型电力系统的挑战与展望[J]. 中国电机工程学报,2022,42(8):2806-2819.
ZHANG Zhigang, KANG Chongqing. Challenges and prospects for constructing the new-type power system towards a carbon neutrality future[J]. Proceedings of the CSEE, 2022, 42(8): 2806-2819.
- [2] 肖先勇,郑子莹. “双碳”目标下新能源为主体的新型电力系统:贡献、关键技术与挑战[J]. 工程科学与技术,2022,54(1):47-59.
XIAO Xianyong, ZHENG Zixuan. New power systems dominated by renewable energy towards the goal of emission peak & carbon neutrality: contribution, key techniques, and challenges[J]. Advanced Engineering Sciences, 2022, 54(1): 47-59.
- [3] 郑海林,朱振山,温步瀛,等. 多主体博弈下基于改进 NashQ 算法的风电场调度策略[J]. 电力科学与技术学报,2022,37(6):62-72.
ZHENG Hailin, ZHU Zhenshan, WEN Buying, et al. A wind power dispatching strategy based on improved NashQ under multi-agent game[J]. Journal of Electric Power Science and Technology, 2022, 37(6): 62-72.
- [4] 赵熙临,姚业佩,何晶晶,等. 考虑风机分组的风储联合辅助调频双目标预测优化方法[J]. 电网与清洁能源,2021,37(10):59-66.
ZHAO Xilin, YAO Yeppei, HE Jingjing, et al. A dual-objective prediction and optimization method of wind-storage combined auxiliary frequency regulation considering wind turbine grouping [J]. Power System and Clean Energy, 2021, 37(10): 59-66.
- [5] 蒋建东,孙书凯,董存,等. 风电中长期电量预测研究现状[J]. 高电压技术,2022,48(2):409-419.
JIANG Jiandong, SUN Shukai, DONG Cun, et al. Research status of mid-long term wind power generation forecasting [J]. High Voltage Engineering, 2022, 48(2): 409-419.
- [6] 宋家康,彭勇刚,蔡宏达,等. 考虑多位置 NWP 和非典型特征的短期风电功率预测研究[J]. 电网技术,2018,42(10):3234-3242.
SONG Jiakang, PENG Yonggang, CAI Hongda, et al. Research of short-term wind power forecasting considering multi-location NWP and uncanonical feature[J]. Power System Technology, 2018, 42(10): 3234-3242.
- [7] 孙荣富,张涛,和青,等. 风电功率预测关键技术及应用综述[J]. 高电压技术,2021,47(4):1129-1143.
SUN Rongfu, ZHANG Tao, HE Qing, et al. Review on key technologies and applications in wind power forecasting[J]. High Voltage Engineering, 2021, 47(4): 1129-1143.
- [8] 王鑫,李慧,叶林,等. 考虑风速波动特性的 VMD-GRU 短期风电功率预测[J]. 电力科学与技术学报,2021,36(4):20-28.
WANG Xin, LI Hui, YE Lin, et al. VMD-GRU based short-term wind power forecast considering wind speed fluctuation characteristics[J]. Journal of Electric Power Science and Technology,

- 2021,36(4):20-28.
- [9] 蔡祯祺. 基于数值天气预报 NWP 修正的 BP 神经网络风电功率短期预测研究[D]. 杭州:浙江大学,2012.
CAI Zhenqi. Study on short-term wind power prediction based on BP neural network modified by NWP numerical weather forecast[D]. Hangzhou: Zhejiang University, 2012.
- [10] OKADA M, ICHIZAWA T, NAKAMURA Y, et al. Development of a wind power ramp forecast system by a statistical and meteorological approach[J]. *Grand Renewable Energy Proceedings*, 2018, 1(0):130-.
- [11] 赵凌云, 刘友波, 沈晓东, 等. 基于 CEEMDAN 和改进时间卷积网络的短期风电功率预测模型[J]. *电力系统保护与控制*, 2022, 50(1):42-50.
ZHAO Lingyun, LIU Youbo, SHEN Xiaodong, et al. Short-term wind power prediction model based on CEEMDAN and an improved time convolutional network[J]. *Power System Protection and Control*, 2022, 50(1):42-50.
- [12] 史加荣, 赵丹梦, 王琳华, 等. 基于 RR-VMD-LSTM 的短期风电功率预测[J]. *电力系统保护与控制*, 2021, 49(21):63-70.
SHI Jiarong, ZHAO Danmeng, WANG Linhua, et al. Short-term wind power prediction based on RR-VMD-LSTM[J]. *Power System Protection and Control*, 2021, 49(21):63-70.
- [13] 黄慧, 贾嵘, 师小雨, 等. 考虑机组动态特性的超短期风电功率预测及不确定性量化分析[J]. *电力系统保护与控制*, 2021, 49(8):109-117.
HUANG Hui, JIA Rong, SHI Xiaoyu, et al. Ultrashort-term wind power prediction considering the dynamic characteristics of a unit and uncertainty quantitative analysis[J]. *Power System Protection and Control*, 2021, 49(8):109-117.
- [14] 孙蓉, 李强, 罗海峰, 等. 基于自适应移动平滑与时间卷积网络误差修正的风电功率预测[J]. *全球能源互联网*, 2022, 5(1):11-22.
SUN Rong, LI Qiang, LUO Haifeng, et al. Wind power forecasting based on error correction using adaptive moving smoothing and time convolution network[J]. *Journal of Global Energy Interconnection*, 2022, 5(1):11-22.
- [15] 何健伟, 曹渝昆. LSTM-RF 的中长期风电功率组合预测方法[J]. *上海电力大学学报*, 2020, 36(4):341-350.
HE Jianwei, CAO Yukun. Wind power mid-long term load forecasting based on LSTM-RF combination forecasting method[J]. *Journal of Shanghai University of Electric Power*, 2020, 36(4):341-350.
- [16] 李飞, 纪元. 基于高层气象大数据的风电场中长期风功率预测研究[J]. *电力大数据*, 2020, 23(2):66-72.
LI Fei, JI Yuan. Study on medium and long-term wind power prediction of wind farm based on high-level meteorological big data[J]. *Power Systems and Big Data*, 2020, 23(2):66-72.
- [17] 张永蕊, 阎洁, 林爱美, 等. 多点数值天气预报风速和辐照度集中式修正方法研究[J]. *发电技术*, 2022, 43(2):278-286.
ZHANG Yongrui, YAN Jie, LIN Aimei, et al. Integrated correction method of multi-point numerical weather prediction wind speed and irradiance[J]. *Power Generation Technology*, 2022, 43(2):278-286.
- [18] 刘芳. 基于改进 BP 神经网络的风电功率预测方法研究[D]. 杭州:浙江大学,2020.
LIU Fang. Research on wind power forecasting method based on improved BP neural network[D]. Hangzhou: Zhejiang University, 2020.
- [19] 梅睿, 吕志勇, 顾文, 等. 基于主成分分析和谱聚类的短期风功率预测[J]. *现代电力*, 2023, 40(1):35-41.
MEI Rui, LYU Zhiyong, GU Wen, et al. Short-term wind power forecast based on principal component analysis and spectral clustering[J]. *Modern Electric Power*, 2023, 40(1):35-41.
- [20] LU T, WANG Y. Prediction model construction for ischemic stroke recurrence with BP network and multivariate logistic regression and effect of individualized health education[J]. *Computational and Mathematical Methods in Medicine*, 2022, 2022:4284566.
- [21] 张天培, 王成亮, 崔恒志, 等. 基于 WNN 与 FCM 的电动汽车动态充电负荷预测方法[J]. *电力工程技术*, 2021, 40(1):167-174.
ZHANG Tianpei, WANG Chengliang, CUI Hengzhi, et al. Dynamic charging load prediction method of electric vehicle based on wavelet neural network and FCM[J]. *Electric Power Engineering Technology*, 2021, 40(1):167-174.
- [22] 王宽. 基于 IPSO-BP 神经网络的风电功率预测研究[D]. 银川:宁夏大学,2022.
WANG Kuan. Research on short-term wind power forecasting based on IPSO-BP neural network[D]. Yinchuan: Ningxia University, 2022.
- [23] ABOUTALEB A, SAYYAFAN A, SIVAKUMAR K, et al. Deep neural network-based detection and partial response equalization for multilayer magnetic recording[J]. *IEEE Transactions on Magnetics*, 2021, 57(3):1-12.
- [24] 苗长新, 王霞, 李昊, 等. 基于数值天气预报风速误差修正的风电功率日前预测[J]. *电网技术*, 2022, 46(9):3455-3464.
MIAO Changxin, WANG Xia, LI Hao, et al. Wind power day-ahead forecast based on wind speed error correction of numerical weather forecast[J]. *Power System Technology*, 2022, 46(9):3455-3464.
- [25] 江长明, 杨健, 柳玉, 等. 基于数据驱动的风电功率预测误差解耦评价方法[J]. *电力系统自动化*, 2021, 45(1):105-113.
JIANG Changming, YANG Jian, LIU Yu, et al. Data-driven decoupling evaluation method of wind power prediction error[J]. *Automation of Electric Power Systems*, 2021, 45(1):105-113.
- [26] 栾毅, 杨永强, 剡文林. 基于相似日和人工神经网络的风电功率短期预测研究[J]. *能源与环保*, 2018, 40(10):140-146.
LUAN Yi, YANG Yongqiang, YAN Wenlin. Research on short-term forecast of wind power based on similar day and artificial

neural network [J]. China Energy and Environmental Protection, 2018, 40(10): 140-146.

[27] 周宁伊. 基于机器学习的风电功率超短期预测[D]. 济南: 山东师范大学, 2021.

ZHOU Ningyi. Ultra-short-term prediction of wind power based on machine learning [D]. Jinan: Shandong Normal University, 2021.

[28] 刘兴, 王艳, 纪志成. 基于随机森林的风电功率短期预测方法[J]. 系统仿真学报, 2021, 33(11): 2606-2614.

LIU Xing, WANG Yan, JI Zhicheng. Short-term wind power prediction method based on random forest [J]. Journal of System Simulation, 2021, 33(11): 2606-2614.

[29] 李仕成, 田丽, 彭求志, 等. 基于梯度提升决策树的风电功率预测[J]. 南阳理工学院学报, 2019, 11(6): 58-61.

LI Shicheng, TIAN Li, PENG Qiuzhi, et al. Wind power prediction based on gradient boosting decision tree [J]. Journal of Nanyang Institute of Technology, 2019, 11(6): 58-61.

作者简介:



宋家康

宋家康(1995), 男, 硕士, 助理工程师, 从事人工智能技术在电网调控领域的应用工作 (E-mail: sjk171@zju.edu.cn);

赵建勇(1987), 男, 博士, 讲师, 研究方向为综合能源系统优化配置及能量管理技术、新能源发电技术;

孙海霞(1974), 女, 硕士, 高级工程师, 从事继电保护、自动化工作。

Wind power prediction and improvement algorithm based on multi-objective collaborative training

SONG Jiakang¹, ZHAO Jianyong², SUN Haixia¹, WANG Hualei¹, NIAN Heng², ZHANG Sen²

(1. State Grid Lianyungang Power Supply Company of Jiangsu Electric Power Co., Ltd., Lianyungang 222000, China;

2. College of Electrical Engineering Zhejiang University, Hangzhou 310027, China)

Abstract: Under the 'dual carbon' goal, the transformation of the power system is accelerating, and wind power prediction technology is of great significance to the construction of a new power system with a high proportion of new energy. In order to improve the accuracy and robustness of wind power prediction, an numerical weather prediction (NWP) implicit correction algorithm based on multi-objective collaborative training is proposed. Firstly, the necessity of NWP correction and the problems of the two-step prediction method based on NWP explicit correction are analyzed. Then, aiming at the problems existing in the two-step prediction method, the optimization method based on multi-objective collaborative training uses the neural network to perform NWP implicit correction, train the model in an end-to-end manner, and realize the functions of NWP implicit correction and wind power prediction at the same time. Combined with the measured data of a wind farm, the specific calculation case analysis proves that the proposed algorithm has an improving effect on short-term, medium- and long-term wind power prediction. In addition, the algorithm only requires one network and avoids secondary calculation, saving computing and storage costs.

Keywords: wind power forecasting; numerical weather prediction (NWP) implicit correction; neural networks; improvement algorithm; multi-objective collaborative training; two-step forecasting method

(编辑 李栋)