计及误差时间相依性的风电功率超短期条件概率预测

王 森,孙永辉,周 衍,王建喜,侯栋宸,张林闯 (河海大学 能源与电气学院,江苏 南京 210098)

摘要:针对单一参数化建模误差集粗糙的问题,基于风电功率历史特征进行建模,集成深度置信网络的特征 提取和粒子群优化算法的寻优能力,分析预测误差时间相依性,实现误差修正。分析误差样本集,建立计及 误差时间相依性的风电功率超短期条件概率预测模型。基于我国吉林省某风电场实际数据进行算例分析, 结果表明所提模型可有效提高预测质量。

关键词:深度置信网络;风电功率预测;超短期;误差修正;条件概率预测 中图分类号:TM 614 文献标志码:A

DOI:10.16081/j.epae.202205011

0 引言

随着传统化石能源的日益枯竭,环境污染问题 日趋严重。在我国明确提出"3060"碳排放目标后, 以风电、光伏为代表的可再生能源发电快速增长。 其中,风电由于无污染、取之不竭等优势受到广泛关 注^[1]。近年来,风电开发利用进入快速发展阶段,但 是由于受天气因素的影响较大,风电具有很强的随 机性和波动性^[2],同时,风电在电力系统中的渗透率 不断提升,给电力系统的安全稳定运行带来了极大 挑战。准确的风电功率预测是解决上述问题的关 键,这对于电力系统稳定运行、电力市场竞价、备用 容量优化、储能容量优化均有重要意义^[35]。

深度学习是对人工神经网络的深度拓展,可通 过多层算法使模型获得更好的特征表达^[6]。文献 [7]提出深度置信网络DBN(Deep Belief Network) 可从原始数据中构造出新的数据特征并可以将其应 用于电力系统的研究中。文献[8]将原始高维特征 输入DBN,充分利用深层架构的提取优势,提高暂态 稳定评估的准确率。文献[9]将DBN用于故障数据 的特征提取,提高故障诊断的准确率。DBN由于强 大的特征筛选能力,被广泛应用于电力系统的设备 故障诊断、配电网无功优化、模式识别和窃电行为检 测等领域中。

目前,风电功率预测的方法主要分为两大类:一 类对风电功率进行确定性预测,即点预测,电力调 度、发电厂、场站运维等部门除了需要点预测结果之 外,还需要风电可能出力范围,仅给出点预测值不能

收稿日期:2021-07-12;修回日期:2022-03-14 在线出版日期:2022-04-12

基金项目:国家重点研发计划项目(促进可再生能源消纳的风电/光伏发电功率预测技术及应用)(2018YFB0904200)

Project supported by the National Key R&D Program of China (Technology and Application of Wind Power / Photovoltaic Power Prediction for Promoting Renewable Energy Consumption)(2018YFB0904200) 完全满足其需要;另一类考虑风电出力的随机性与 波动性,基于风电功率的概率密度函数刻画风电功 率范围,即概率预测。由于点预测不可避免地存在 误差,而概率预测能提供更多信息,因此,概率预测 逐渐成为国内外研究的热点。

国内外学者对风电功率预测、误差修正和参数 化概率预测建模进行了深入研究,取得了较丰富的 成果。文献[10]提出基于波动的误差修正方法,考 虑风电功率的波动性过程,建立误差与气象指标之 间的关系。文献[11]提出一种考虑风电功率爬坡事 件的超短期功率预测和校正模型,利用旋转门算法 识别功率爬坡事件,实现风电功率预测结果的修正。 文献[12]分析物理拟合误差对预测误差的影响,准 确描述各风速段的不同误差分布。文献[13]研究预 测误差的概率分布情况,建立不同预测值范围内多 误差分布模型。文献[14]将回归模型不确定性方差 与残差噪声的方差相结合,准确计算出概率预测区 间。需要指出的是,上述文献主要是对误差修正和 概率预测分别进行研究,未能有效地将误差修正和 概率预测相结合。

综上,本文提出计及误差时间相依性的风电功 率超短期条件概率预测模型。首先,基于风电功率 历史特征进行建模,利用 DBN 和粒子群优化 PSO (Particle Swarm Optimization)算法进行风电功率点 预测;其次,基于预测误差的时间相依性特点,建立 误差修正模型,对预测结果进行修正;然后,对修正 后的预测误差进行条件建模,建立误差集优化模型, 实现风电功率超短期条件概率预测;最后,通过实际 算例验证本文所提模型可有效提高风电功率超短期 概率预测质量。

1 风电功率超短期预测模型

1.1 DBN 基本原理

2006年, Hilton利用逐层学习策略对样本数据 进行训练,获得了一个效果较好的深层神经网络,即 DBN,打破了深层网络难以被训练的局面。

1.1.1 受限玻尔兹曼机

受限玻尔兹曼机 RBM(Restricted Boltzmann Machine)嵌套叠加组成 DBN, RBM 层内神经元之间没 有连接,即图论中描述的二部图,如附录 A 图 A1 所 示,可见层和隐含层之间的能量^[15]定义为:

$$E(\mathbf{v}, \mathbf{h}) = -\sum_{i=1}^{m} a_i v_i - \sum_{j=1}^{n} b_j h_j - \sum_{i=1}^{m} \sum_{j=1}^{n} v_i w_{ij} h_j \qquad (1)$$

式中:*E*(*v*,*h*)为RBM的能量函数,*v*为可见层状态向 量,*h*为隐含层状态向量;*m*、*n*分别为可见层和隐含 层神经元个数;*a_i、v_i*分别为可见层第*i*个神经元的偏 置和状态,第1个可见层的输入为风电功率历史数 据向量;*b_j、h_j*分别为隐含层第*j*个神经元的偏置和 状态,该层输入为可见层输出;*w_{ij}*为第*i*个可见层和 第*j*个隐含层之间的连接权重。

可见层和隐含层的联合概率p(v, h)定义为:

$$p(\boldsymbol{v}, \boldsymbol{h}) = \frac{1}{\sum_{\boldsymbol{v}, \boldsymbol{h}} \exp(-E(\boldsymbol{v}, \boldsymbol{h}))} \exp(-E(\boldsymbol{v}, \boldsymbol{h})) \quad (2)$$

根据给定的可见层状态以及模型训练后的参数,可计算出隐含层状态的条件概率p(h|v)为:

$$p(\boldsymbol{h}|\boldsymbol{v}) = \frac{p(\boldsymbol{v},\boldsymbol{h})}{p(\boldsymbol{v})} = \frac{p(\boldsymbol{v},\boldsymbol{h})}{\sum p(\boldsymbol{v},\boldsymbol{h})}$$
(3)

式中:p(v)为可见层的边际概率。

对于给定的风电功率历史时间序列,下一层隐 含层的数值取决于上一层可见层的数值特征,通过 该过程可建立相邻2层之间的数值关系,以便完成 后续数值特征筛选。将式(2)代入式(3)可得:

$$p(\boldsymbol{h}|\boldsymbol{v}) = \prod_{i} p(h_{i}|\boldsymbol{v})$$
(4)

式中: $p(h_j|v)$ 为 h_j 的全条件概率。

假设给定可见层状态,则某个隐含层状态为1的概率 $p(h_i=1|v)$ 为:

$$\boldsymbol{v}\left(h_{j}=1|\boldsymbol{v}\right)=\boldsymbol{\sigma}\left(\sum_{i}w_{ij}v_{i}+b_{j}\right)$$
(5)

同理,根据给定的隐含层状态,可计算可见层状态的条件概率 $p(v_i=1|h)$ 为:

$$p(v_i=1|\boldsymbol{h}) = \sigma\left(\sum_i w_{ij}h_j + a_i\right)$$
(6)

式中: $\sigma(\cdot)$ 为激活函数,本文模型采用Sigmoid函数。根据相邻2层之间的条件概率,结合训练过程, 完成数值关系的特征筛选。

1.1.2 DBN训练

当反向传播 BP(Back Propagation)神经网络为 单隐含层时,效率较高,而当堆积到多层隐含层时, 效率就会大幅降低,因此,BP神经网络在浅层神经 网络中应用较广,多用于解决一些比较简单的映射 建模问题,但由于其隐含层数较少,所以映射能力十 分有限,并且容易产生局部最优问题。为了克服传 统神经网络的训练时间长和局部最优等缺点,DBN 训练可以分为正向预训练和反向微调2个过程,对 RBM进行无监督逐层训练,再进行反向微调。

采用对比散度 CD(Contrastive Divergence)算法 进行正向预训练^[16],通过最大化似然函数求得网络 参数,对 RBM 进行无监督预训练,根据上下层间的 参数误差更新各参数:

$$\begin{cases} w_{ij} = w_{ij} + \lambda \left(\left\langle v_i h_j \right\rangle_{\text{data}} - \left\langle v_i h_j \right\rangle_{\text{model}} \right) \\ a_i = a_i + \lambda \left(\left\langle v_i \right\rangle_{\text{data}} - \left\langle v_i \right\rangle_{\text{model}} \right) \\ b_j = b_j + \lambda \left(\left\langle h_j \right\rangle_{\text{data}} - \left\langle h_j \right\rangle_{\text{model}} \right) \end{cases}$$
(7)

式中:λ为学习率;〈·〉_{data}表示数据分布的期望;〈·〉_{model} 表示 RBM 定义的期望,由吉布斯采样的数据分布 决定。

反向微调是通过监督学习对网络参数进行微 调,一般采用梯度下降算法,但考虑到该算法容易陷 入局部最优,本文采用Wake-Sleep算法进行反向微 调^[16]。Wake过程又被称为认知过程,对于输入的风 电功率历史数据,通过式(5)计算条件概率,重新采 样得到新样本,新样本虽不具有物理意义,但通过微 调下层参数可以使得重建数据特征与原始风电功率 历史数据特征尽可能相似。Sleep过程又被称为生 成过程,对于Wake过程得到的新样本,通过式(6)计 算条件概率,通过微调上层参数使得重建数据特征 与上层数据特征尽可能相似。2个过程不断交替进 行,直到收敛,完成对风电功率历史数据数值特征的 提取和预测。DBN结构如图1所示。



Fig.1 Structure of DBN

1.2 基于DBN-PSO的风电功率超短期预测模型 高分辨率气象实测数据有利于模型预测精度的 提升^[17],由于数值天气预报不可避免地存在误差,而 风电功率历史数据采样稳定且能准确反映风机本身 物理特性,因此在进行超短期预测时可仅采用风电 功率历史数据作为模型输入^[18]。

对风电功率历史数据时间序列进行窗口滚动以 提取数据并构建模型输入矩阵*X*,本文所选择的输 入输出模型如附录A图A2所示。

$$\boldsymbol{X} = \begin{bmatrix} x_{1,1} & \cdots & x_{1,r} \\ \vdots & \vdots \\ x_{T,1} & \cdots & x_{T,r} \end{bmatrix}$$

式中:x_{t,j}(t=1,2,...,T;j=1,2,...,r)为t时刻的第j 个特征,T为采样时刻数,r为特征数,本文取r=10, 即待预测时刻前10个采样点的风电功率实际数据。

对于构建的风电功率历史数据集 $\{(\mathbf{x}_{t}, \hat{p}_{t})\}_{t=1}^{t}$, 可建立 DBN-PSO模型,其中: \mathbf{x}_{t} 为t时刻 DBN 预测模 型输入向量,是风电功率历史数据; \hat{p}_{t} 为t时刻 DBN 预测模型输出,是风电功率预测值。与主成分分析 PCA(Principal Component Analysis)直接对特征进 行向量表达的方式不同,DBN模型通过1.1节自下而 上的概率计算与自上而下的反向微调训练完成特征 自主筛选。通过联合概率分布特性,下一层隐含层 可表现出上一层特征的高阶相关性,实现X的特征 自主筛选。同时,为了避免人为设置参数的偶然性, 采用 PSO 算法^[19-20]对 DBN 隐含层中的节点数进行寻 优。模型表达式为:

$$\hat{p}_t = J(\mathbf{x}_t) \tag{8}$$

式中:J(·)为DBN模型输入与输出之间的映射函数。

在实际工程应用中,待预测时刻真值为未知值, 即预测误差未知,因此,将训练集输入DBN模型中 进行训练,根据训练集再预测的误差值,PSO算法优 化约束为该误差*E*_{train}最小:

$$\min E_{\text{train}} = \hat{P}_{\text{train}} - P_{\text{train}} \tag{9}$$

式中: \hat{P}_{train} 为训练集预测功率值; P_{train} 为训练集实际 功率值。

经过DBN-PSO算法训练和优化后的模型可表示为:

$$\hat{p}_{i} = J(\boldsymbol{x}_{i}, \boldsymbol{w}, \boldsymbol{a}, \boldsymbol{b})$$
(10)

式中:w、a、b分别为预测模型权重以及可见层和隐含层偏置的最优参数。

2 计及误差时间相依性的风电功率超短期 条件概率预测

2.1 计及误差时间相依性的误差修正模型

由于现有研究致力于提高预测模型的精确度, 因此,更加关注模型预测对象的准确性,对预测误差 矫正聚焦于纵向误差,即模型输出的预测值与实际 值之间的差值,忽略了误差在时间上的相依性。由 于天气具有很强的惯性,不会在极短的时间内发生 突变,因此采样点之间存在很强的时间相依性,可通 过相关性分析得到。基于此,本文通过不同时刻的 功率对当前时刻的功率进行修正,即从误差时间相 依性的角度确定一个时间修正系数,实现预测误差 的修正。对预测误差在时间相依性上的矫正,也可 达到预测对象矫正的目的,将在水平方向上的时间 误差定义为横向误差^[21],如附录A图A3所示。

以数据分辨率为15min为例,即超短期预测可 分为16个时间尺度预测模型。不同时间尺度的预 测造成不同的时间相依性,为准确获得时间修正 系数,同时考虑工程的可操作性,将整个数据集中 80%~90%的数据组成交叉验证集,计算误差修正 系数。文献[21]提出一种横向误差修正方法,但是 该方法需要进行功率爬坡识别。本文利用交叉验证 集的已知数据进行误差修正系数搜索的步骤如下。

1)平滑数据集,计算平滑后各采样点之间的导数,确定功率上爬坡和下爬坡转折点。

2)选取爬坡中间时刻 Γ ,计算预测值和该预测 时刻之前实际值的差值 E_r :

$$\boldsymbol{E}_{\Gamma} = \hat{\boldsymbol{p}}_{\text{array} \Gamma} \boldsymbol{\Gamma} \boldsymbol{I} - \boldsymbol{P}_{\text{array} \Gamma} \tag{11}$$

式中: $\hat{p}_{\text{cross},\Gamma}$ 为 Γ 时刻交叉验证集预测功率值;I为元 素值均为1的列向量; $P_{\text{cross},\Gamma}$ 为 Γ 时刻及之前交叉验 证集的实际功率值。

3)选取*E*_r中最小值所对应实际功率值的时刻 作为待修正时刻,并计算时间差:

$$\Delta \tau = \left| \hat{\tau} - \tau \right| \tag{12}$$

式中: $\Delta \tau$ 为时间修正系数; $\hat{\tau}$ 为 E_{Γ} 中最小值对应预测时刻; τ 为 E_{Γ} 中最小值对应实际功率值的时刻。

4)功率上爬坡和下爬坡的转折时间可能导致产 生多个时间修正系数,本文将时间修正系数集ΔT中 出现频次最高的时间修正系数作为最终系数。

2.2 风电功率超短期条件概率模型

参数化建模由于具有速度快、易实现的优势,成 为实际工程中一种常用的建模方式。根据中心极限 定理可知,在一定的样本下,风电功率点预测误差服 从高斯分布。

利用常规参数化概率预测模型构建的预测区间 宽度相等,所得预测结果较为粗糙,因此,本文在常 规参数化概率预测模型的基础上,提出以筛选条件 对误差集进行优化,对满足条件的数据构建概率预 测模型,达到提高区间质量的目的。本文条件概率 预测模型的构建过程如下。

1)考虑到实际工程应用中待预测时刻实际功率 值未知,为避免数据泄露,计算测试集中功率预测值 与训练集中功率预测值的差值 e:

$$e = \hat{P}_{\text{test}} - \hat{P}_{\text{train}} \tag{13}$$

式中: P̂_{test} 为测试集中功率预测值; P̂_{train} 为训练集中

功率预测值。

2)按照一定比例(该比例以满足置信度为约束, 通过优化算法确定)取出差值中前ζ个最小的预测 差值及相应预测误差,构成新数据集。

3)计算新数据集对应的实际功率值和预测功率 值之间的误差。

4)计算新数据集的方差和标准差,分别根据式 (14)和式(15)计算待预测时刻风电功率预测区间的 上限值U^a_b以及下限值L^a_b,即为该点区间的上限值和 下限值。

$$U_{\rm b}^{\alpha} = \hat{P}_{\rm test} + z_{1-\alpha/2} \sigma_{\rm b} \tag{14}$$

$$L_{\rm b}^{\alpha} = \dot{P}_{\rm test} - z_{1-\alpha/2} \sigma_{\rm b} \tag{15}$$

式中: $z_{1-\alpha/2}$ 为置信度为 α 的分位数; σ_{b} 为新数据集的标准差。

5)重复步骤4),计算测试集中每个点的上限值 和下限值,将所有点顺序连接,构成整个预测区间的 上限和下限。

计及误差时间相依性的风电功率超短期条件概 率预测流程图如图2所示。本文建立计及误差时间 相依性的风电功率超短期条件概率预测模型,利用 DBN 对风电功率历史时间序列进行特征筛选,为避 免参数设置的偶然性,采用 PSO 算法进行网络参数 寻优,建立超短期点预测模型。与文献[21]中模型 相比,本文模型结构简单,且显著提高了点预测质 量。与文献[14]中方法相比,本文方法通过对误差 集进行优化有效提高了概率预测的区间质量。



图2 风电功率超短期条件概率预测流程图

Fig.2 Flowchart of ultra-short term conditional probability prediction of wind power

2.3 评价指标

为了从不同方面评价所提模型的性能,采用不同评价指标对预测结果进行分析。对于点预测,采用平均绝对百分比误差 MAPE(Mean Absolute Percent Error)和均方根误差 RMSE(Root Mean Square Error)指标^[22];对于概率预测,采用预测区间覆盖度 PICP(Prediction Interval Coverage Probability)、平均区间宽度 MIW(Mean Interval Width)和综合得分指标。

MAPE 表达式为:

$$e_{\text{MAPE}} = \frac{1}{T} \sum_{i=1}^{T} \left| \frac{\hat{p}_i - p_i}{C} \right| \times 100 \%$$
(16)

式中: e_{MAPE} 为MAPE; p_t 为t时刻风电功率实际值; C为风机装机容量。

RMSE表达式为:

$$e_{\text{RMSE}} = \sqrt{\frac{1}{T} \sum_{t=1}^{T} \left(\hat{p}_{t} - p_{t} \right)^{2}}$$
(17)

式中:e_{RMSE}为RMSE。

MIW 表达式为:

$$M = \frac{1}{T} \sum_{t=1}^{T} \left(u_t - l_t \right)$$
(18)

式中:M为MIW; u_i 、 l_i 分别为t时刻风电功率预测区间的上限值和下限值。

PICP表达式为:

$$F = \frac{1}{T} \sum_{t=1}^{T} K_t \times 100 \%$$
 (19)

$$K_{i} = \begin{cases} 0 & p_{i} \notin (l_{i}, u_{i}) \\ 1 & p_{i} \in (l_{i}, u_{i}) \end{cases}$$
(20)

式中:F为PICP。

$$\Omega_{t} = \begin{cases}
-2\alpha\delta_{t}^{\alpha} - 4\left(l_{t} - p_{t}\right) & p_{t} < l_{t} \\
-2\alpha\delta_{t}^{\alpha} & p_{t} \in [l_{t}, u_{t}] \\
-2\alpha\delta_{t}^{\alpha} - 4\left(p_{t} - u_{t}\right) & p_{t} > u_{t}
\end{cases} (21)$$

$$=u_{i}-l_{i}$$
(22)

式中: Ω_t 为t时刻的综合得分; δ_t^{α} 为t时刻在置信度 1- α 下的区间宽度。

 δ^{α}_{t}

综合得分是对概率预测区间整体性能的评价, 其值越接近0,说明概率预测整体质量越高。

3 算例分析

本文基于我国吉林省某风电场实际数据进行算例分析,该风电场装机容量为49.5 MW,选取该风电场2019年1月数据对本文模型进行验证。采样点间隔,即时间分辨率为15 min。本文以2h时间尺度为例进行超短期预测测试。

3.1 数据预处理

本文模型采用滚动预测方式,同时为避免累积 误差,每15 min更新一次现场数据。将数据集按照 8:1:1的比例分别划分为训练集、交叉验证集和测 试集。交叉验证集用于确定误差修正系数以及优化 预测模型参数。本文对数据集中的数据进行预处 理,首先对历史功率时间序列进行窗口滑动以提取 数据形成数据集,选取特征数r=10,然后将数据进行 归一化处理以提高模型训练性能和效率,本文选择 线性函数进行归一化,即进行最大最小处理^[14],归一 化之后的数据被压缩到[0,1]区间,为了直观分析预 测的性能,最终的预测结果需要进行反归一化处理。

3.2 模型预测结果

为了体现本文所提算法的优势,将本文DBN、 BP及文献[14]的极限学习机ELM(Extreme Learning Machine)进行点预测结果的对比。不同预测 算法的点预测结果如图3所示,评价指标结果如表1 所示。





Fig.3 Results of point prediction for different prediction algorithms

表1 不同预测算法的评价指标结果

Table 1 Results of evaluation indexes for different prediction algorithms

	1	e
算法	MAPE / %	RMSE / MW
ELM	13.88	8.462 0
BP	13.26	8.402 0
DBN	12.62	8.123 9

由图3和表1可知,本文DBN在风电功率出现 爬坡时有较好的预测性能,尤其是在采样点81— 121,而在该采样点范围内,BP和ELM虽然可以有效 地跟踪功率的爬坡,但是由于鲁棒性较差,当风电功 率连续上下爬坡交替时预测性能不佳,这说明DBN 可有效提取特征以及改善模型的预测性能。

首先,根据实际参数选取经验和算法运算情况 确定隐含层层数,通过实验分别计算不同层数的预 测结果,综合考虑计算效率和预测效果,本文模型隐 含层设置为2层最佳。然后,通过PSO算法优化确 定每层神经元个数,优化过程如图4所示。由图可 知,在寻优迭代过程中,第1层神经元个数在20附近 收敛,第2层神经元个数在30附近收敛,因此,DBN 中2层RBM神经元个数寻优结果分别为20与28。



图4 PSO算法寻优结果

Fig.4 Optimization results of PSO algorithm

根据式(14)、(15),基于点预测的结果,计算点 预测误差分布的密度函数,建立概率预测区间,因 此,点预测的准确性是影响概率预测性能的关键。 误差修正前后的预测结果对比如图5所示,评价指 标对比如表2所示。通过对比分析可知,考虑误差 时间相依性的误差修正模型可以显著提高模型的预 测性能。



图5 修正前后预测结果对比



表2 误差修正前、后评价指标比较

 Table 2
 Comparison of evaluation indexes between before and after error correction

模型	MAPE / %	RMSE / MW
修正前	12.70	8.1961
修正后	6.39	4.4431

为了验证所提条件概率预测模型的可行性,将 条件概率预测和普通概率预测进行对比,概率预测 结果如图6所示(以85%置信度为例),评价指标如 表3所示。不同置信度下的条件概率预测结果如附 录A图A4所示。由结果可知,本文所提条件概率预 测模型在满足置信区间的同时可有效减小区间 宽度。



图6 概率预测结果

Fig.6 Results of probability prediction

表3 概率预测评价指标对比

Table 3 Comparison of evaluation indexes of

probability prediction					
模型	置信度 / %	PICP / %	MIW / MW	综合得分	
普通概率	85	93.28	16.53	-5.50	
	90	98.08	19.96	-4.11	
	95	99.60	24.57	-2.48	
条件概率	85	85.38	12.76	-5.34	
	90	90.12	15.42	-3.84	
	95	95.26	18.57	-2.01	

4 结论

本文基于风电功率历史实测功率数据,将DBN 与PSO算法寻优结合,考虑点预测误差时间相依性, 提出以筛选条件对误差集进行优化,建立计及误差 时间相依性的风电功率超短期条件概率预测模型, 提高概率预测质量。基于我国吉林省某风电场的实 际数据进行仿真测试,验证了所提模型的有效性。

附录见本刊网络版(http://www.epae.cn)。

参考文献:

- [1] 钱政,裴岩,曹利宵,等.风电功率预测方法综述[J].高电压 技术,2016,42(4):1047-1060.
 QIAN Zheng, PEI Yan, CAO Lixiao, et al. Review of wind power forecasting method[J]. High Voltage Engineering,2016, 42(4):1047-1060.
- [2]杨茂,张罗宾.基于数据驱动的超短期风电功率预测综述[J]. 电力系统保护与控制,2019,47(13):171-186.
 YANG Mao,ZHANG Luobin. Review on ultra-short term wind power forecasting based on data-driven approach[J]. Power System Protection and Control,2019,47(13):171-186.
- [3]牛哲文,余泽远,李波,等.基于深度门控循环单元神经网络的短期风功率预测模型[J].电力自动化设备,2018,38(5): 36-42.
 NIU Zhewen,YU Zeyuan,LI Bo, et al. Short-term wind power forecasting model based on deep gated recurrent unit neural network[J]. Electric Power Automation Equipment,2018,38(5): 36-42
- [4] ZHAO Y N, YE L, WANG W S, et al. Data-driven correction approach to refine power curve of wind farm under wind curtailment[J]. IEEE Transactions on Sustainable Energy, 2018,9(1):95-105.
- [5] ZHANG W J, QUAN H, GANDHI O, et al. Improving probabilistic load forecasting using quantile regression NN with

skip connections[J]. IEEE Transactions on Smart Grid, 2020, 11(6):5442-5450.

[6] 刘方园,王水花,张煜东. 深度置信网络模型及应用研究综述
 [J]. 计算机工程与应用,2018,54(1):11-18,47.
 LIU Fangyuan, WANG Shuihua, ZHANG Yudong. Survey on

deep belief network model and its applications[J]. Computer Engineering and Applications, 2018, 54(1):11-18, 47.

- [7]杨挺,赵黎媛,王成山.人工智能在电力系统及综合能源系统 中的应用综述[J].电力系统自动化,2019,43(1):2-14.
 YANG Ting,ZHAO Liyuan,WANG Chengshan. Review on application of artificial intelligence in power system and integrated energy system[J]. Automation of Electric Power Systems,2019,43(1):2-14.
- [8]朱乔木,党杰,陈金富,等.基于深度置信网络的电力系统暂态 稳定评估方法[J].中国电机工程学报,2018,38(3):735-743.
 ZHU Qiaomu, DANG Jie, CHEN Jinfu, et al. A method for power system transient stability assessment based on deep belief networks[J]. Proceedings of the CSEE, 2018, 38(3): 735-743.
- [9] 李俊卿,陈雅婷,李斯璇. 基于深度置信网络的同步发电机励 磁绕组匝间短路故障预警[J]. 电力自动化设备,2021,41(2): 153-158.

LI Junqing, CHEN Yating, LI Sixuan. Early warning of interturn short circuit fault in excitation windings of synchronous generator based on deep belief network[J]. Electric Power Automation Equipment, 2021, 41(2):153-158.

- [10] 丁明,张超,王勃,等. 基于功率波动过程的风电功率短期预测 及误差修正[J]. 电力系统自动化,2019,43(3):2-9.
 DING Ming, ZHANG Chao, WANG Bo, et al. Short-term forecasting and error correction of wind power based on power fluctuation process[J]. Automation of Electric Power Systems, 2019,43(3):2-9.
- [11] 叶林,路朋,滕景竹,等.考虑风电功率爬坡的功率预测-校正 模型[J]. 电力系统自动化,2019,43(6):49-56.
 YE Lin,LU Peng,TENG Jingzhu, et al. Power prediction and correction model considering wind power ramping events[J].
 Automation of Electric Power Systems,2019,43(6):49-56.
- [12] 丁华杰,宋永华,胡泽春,等. 基于风电场功率特性的日前风电 预测误差概率分布研究[J]. 中国电机工程学报,2013,33(34): 136-144,22.

DING Huajie, SONG Yonghua, HU Zechun, et al. Probability density function of day-ahead wind power forecast errors based on power curves of wind farms[J]. Proceedings of the CSEE, 2013, 33(34):136-144, 22.

- [13] SUN Y H, WANG P, ZHAI S W, et al. Ultra short-term probability prediction of wind power based on LSTM network and condition normal distribution [J]. Wind Energy, 2020, 23 (1):63-76.
- [14] WAN C, XU Z, PINSON P, et al. Probabilistic forecasting of wind power generation using extreme learning machine[J]. IEEE Transactions on Power Systems, 2014, 29(3):1033-1044.
- [15] 马丽叶,刘建恒,卢志刚,等.基于深度置信网络的低压台区理 论线损计算方法[J].电力自动化设备,2020,40(8):140-146.
 MA Liye,LIU Jianheng,LU Zhigang, et al. Theoretical line loss calculation method of low voltage transform district based on deep belief network[J]. Electric Power Automation Equipment,2020,40(8):140-146.
- [16] HINTON G E. Training products of experts by minimizing contrastive divergence [J]. Neural Computation, 2002, 14(8): 1771-1800.
- [17]杨茂,白玉莹.基于多位置NWP和门控循环单元的风电功率

超短期预测[J]. 电力系统自动化,2021,45(1):177-183.

YANG Mao, BAI Yuying. Ultra-short-term prediction of wind power based on multi-location numerical weather prediction and gated recurrent unit[J]. Automation of Electric Power Systems, 2021, 45(1): 177-183.

- [18] WAN C, WANG J H, LIN J, et al. Nonparametric prediction intervals of wind power via linear programming[J]. IEEE Transactions on Power Systems, 2018, 33(1):1074-1076.
- [19] LI C H, YANG S X, NGUYEN T T. A self-learning particle swarm optimizer for global optimization problems[J]. IEEE Transactions on Systems, Man, and Cybernetics-Part B: Cybernetics, 2012, 42(3):627-646.
- [20] 赵洪山,刘辉海.基于性能改善深度置信网络的风电机组主轴 承状态分析[J].电力自动化设备,2018,38(2):44-49.
 ZHAO Hongshan,LIU Huihai. Condition analysis of wind turbine main bearing based on deep belief network with improved performance[J]. Electric Power Automation Equipment, 2018,38(2):44-49.
- [21] 胡亚伟,王筱,晁勤,等.采用横纵向误差平移插值修正的风电 预测精度改善方法[J]. 电网技术,2015,39(10):2758-2765.
 HU Yawei,WANG Xiao,CHAO Qin, et al. A forecasting accu-

racy improvement method for wind power based on phase and level errors translating and interpolating correction[J]. Power System Technology, 2015, 39(10): 2758-2765.

[22] 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.

作者简介:



王 森(1995—),男,博士研究生,主 要研究方向为新能源电力系统建模与优化 控制(**E-mail**:senwang@hhu.edu.cn);

孙永辉(1980—),男,教授,博士研究 生导师,博士,通信作者,主要研究方向为智 慧能源系统规划与优化运行、新能源电力系 统建模与优化控制、能源大数据与人工智能 技术(E-mail:sunyonghui168@gmali.com)。

(编辑 王锦秀)

Ultra-short term conditional probability prediction of wind power considering error time dependence

WANG Sen, SUN Yonghui, ZHOU Yan, WANG Jianxi, HOU Dongchen, ZHANG Linchuang

(College of Energy and Electrical Engineering, Hohai University, Nanjing 210098, China)

Abstract: Aiming at the problem of rough error set of single parametric modeling, the modeling based on wind power historical characteristics is carried out, the capabilities of feature extraction of deep belief network and optimization of particle swarm optimization algorithm are integrated, and the time dependence of prediction error is analyzed to realize error correction. The error sample set is analyzed, and a ultra-short term conditional probability prediction model of wind power is built considering the error time dependence. The case analysis based on the actual data of a wind farm in Jilin province of China is carried out, and results show that the proposed model can effectively improve the prediction quality.

Key words: deep belief network; wind power prediction; ultra-short term; error correction; conditional probability prediction

附录 A



图 A1 受限玻尔兹曼机结构

Fig.A1 Structure of RBM



图 A2 输入输出模型

Fig.A2 Input and output model



采样点

图 A3 横向误差的定义 Fig.A3 Definition of lateral error



Fig.A4 Probability prediction results under different confidence levels