

基于数据物理混合驱动的超短期风电功率预测模型

杨 茂¹, 王 达¹, 王小海², 范馥麟³, 高 博², 王 勃⁴

(1. 现代电力系统仿真控制与绿色电能新技术教育部重点实验室(东北电力大学), 吉林 132012; 2. 内蒙古电力(集团)有限责任公司, 呼和浩特 010040; 3. 思克莱德大学能源与环境学院, 英国格拉斯哥 G11XW; 4. 中国电力科学研究院有限公司新能源与储能运行控制全国重点实验室, 北京 100192)

摘 要: 为提升超短期风电功率预测精度, 提出一种数据-物理混合驱动的超短期风电功率预测方法。首先, 构建一种融合双向门控循环单元的残差网络结构, 将其在测试集的预测结果作为预测模板。然后, 根据风速-风电转换特性, 基于多项式-线性回归模型拟合风电场风速-功率曲线, 在风速高波动时点, 以物理机理透明的风速-功率曲线进行预测。最后, 根据风速波动阈值建立不同模型之间的动态切换机制, 按切换的时点修改模板预测值, 对于修正风速小于切入风速的时点, 将预测值置零。在吉林省某装机容量为 400.5 MW 的风电场提供的数据上进行仿真实验得到, 测试集第 16 步预测的平均归一化均方根误差为 0.158 9, 全部切换中有利切换占比达到 90.86%, 验证了提出的超短期风电功率预测模型的有效性和适用性。

关键词: 风电场; 超短期预测; 数据物理混合驱动; 切换机制; 波动阈值; 深度残差网络

Ultra-short Term Wind Power Prediction Method Based on Data Physics Hybrid Driven Model

YANG Mao¹, WANG Da¹, WANG Xiaohai², FAN Fulin³, GAO Bo², WANG Bo⁴

(1. Key Laboratory of Modern Power System Simulation and Control & Renewable Energy Technology, Ministry of Education, Northeast Electric Power University, Jilin 132012, China; 2. Inner Mongolian Electric Power Group Co., Ltd., Hohhot 010040, China; 3. Institute for Energy and Environment, University of Strathclyde, Glasgow G11XW, England; 4. State Key Laboratory of Operation and Control of Renewable Energy & Storage Systems, China Electric Power Research Institute, Beijing 100192, China)

Abstract: To improve the accuracy of ultrashort-term wind power prediction, a data-physical hybrid-driven ultrashort-term wind power prediction method is proposed. First, the ultrashort-term WPP model with bidirectional recurrent residual net-work is constructed, and the prediction results in the test set are used as the prediction template. Then, a polynomial-linear regression model is utilized to fit the wind speed-power curve of the wind farm, and the wind-power curve (WPC) is used to predict at the high fluctuation points. Finally, a dynamic switching mechanism between different models is established according to the wind speed fluctuation threshold, the template prediction value is modified according to the switching time point, and the prediction value is set to zero for the samples that the corrected wind speed is less than the cut-in wind speed. Experimental validation is carried out with data provided by a wind farm with an installed capacity of 400.5 MW in Jilin province of China, the average normalized root mean square error predicted in step 16 of the test set is 0.158 9, and the favorable switchover accounts for 90.86% of all the switches, which verify the validity and applicability of the proposed ultra-short-term wind power prediction model.

Key words: wind farm; ultra-short-term forecasting; data-physical hybrid driven; switching mechanism; fluctuation threshold; deep residual network

0 引言

随着“双碳”目标的提出, 构建新型电力系统正如火如荼地进行。以风电为代表的新能源被大规

模开发利用, 加速了可再生能源逐步取代传统能源的步伐。根据国家能源局提供的数据, 2021 年我国风电机组累计装机容量达到 328.5 GW, 占全球累计装机总量的 39.2%, 增速同比增长 16.7%, 快于全球其他发达国家。风电的间歇性、随机性和不确定性给电力系统的调峰、调频以及电网调度决策带来了诸多不利因素^[1-3]。此外, 风电高装机容量和高消

基金资助项目: 国家重点研发计划(2018YFB0904200); 内蒙古电力(集团)有限责任公司科技项目(DUKZZZ-YBHT-2021-JSC0401-0015)。Project supported by National Key R&D Program of China (2018YFB0904200), Science and Technology Project of Inner Mongolia Electric Power (Group) Co., Ltd. (DUKZZZ-YBHT-2021-JSC0401-0015).

纳之间的矛盾凸显, 促进我国风电消纳仍然任重道远。

风电功率预测诞生的契机是平衡电力供应和负荷需求, 降低风电的波动性对电网的不利影响^[4]。按照预测的时间尺度, 分为中长期预测、短期预测及超短期预测。其中, 超短期预测提供未来 4 h 内的风电功率预报序列, 对调度侧安排备用容量及制定实时调度计划意义重大, 本文重点对这一预测技术展开研究。按照预测方法, 超短期风电功率预测可分为统计学习方法及物理预测方法^[5-6]。

物理方法通过求解高维的非线性方程组得到风力发电机轮毂高度的风速、风向等信息, 再根据风机的功率曲线计算得到风机的输出功率。这类方法能够较好地反映大气运动的本质, 物理机理清晰且无需累计大量历史数据, 比较适合在建风电场的功率预测^[7]。由于风电场的特殊地理环境以及某些物理现象(如尾流效应、地转风等)通常难以精确描述, 所以物理方法的预测精度在很大程度上依赖于模型和参数的选择^[8]。

统计学习方法是对外在变化规律进行统计推断的过程。与从内部物理规律刻画天气系统演变的动力学方法相比, 统计学方法是基于研究对象的量测信息(即样本)来分析和估计研究对象的外在变化规律(统计特性), 推断其未来发展的趋势^[9]。近年来, 神经网络算法^[10-11]、核函数法(含支持向量机)^[12]和回归方法等人工智能算法因非线性描述能力强、容错性能高、稳定性好等方面的优势, 得到广泛应用。特别是以循环神经网络为代表的深度学习模型的引入, 极大程度地丰富了统计学习方法在风电功率预测领域的应用范围^[13-14]。

以统计模型为基元的组合预测模式被证明能够有效提升超短期风电功率预测精度, 在此背景下不同的组合模式被广泛提出。如文献^[15-16]提出功率序列分解-单独建模-群智能优化参数-预测结果重构的预测模式, 通过降低效率换取预测精度的提升。文献^[17-18]提出残差预测-误差修正的组合预测模式, 在一定程度上减小了预测误差。此外, 还有将多个预测器的预测结果加权组合的预测模式, 等权重法^[19]、熵值法^[20]及贝叶斯法^[21]等算法被用于确定权重组合, 此类方法的精细化程度较高, 但是权重的设定难以达到最优状态, 尤其是时变权重难以自适应确定。尽管当前组合预测模型在一定程度上提升了预测精度, 并被用于工程实践。但是针对不同

波动时点区别建模的组合预测模式尚未开展充分的研究, 特别是由于人工智能算法采用“mse”进行损失评估, 模型训练阶段存在“偷懒”行为, 将输入中最后一个步长的数据经过一定的平均化行为, 映射成对应的输出, 时滞性的存在使得低出力时点预测值偏高。此外, 对于人工智能算法, 时间序列在高波动时点的可预测性也是制约预测精度的主要原因。

本文的目的是建立一种数据-物理混合驱动的超短期风电功率预测模式, 通过构建人工智能模型, 建立多元气象及历史功率输入和预测时段功率输出之间的映射关系。在风速突变时点引入风速-功率曲线的预测功率, 对人工智能模型的预测结果进行修改。对于风速低于切入风速的时点, 将预测功率置零。具体研究内容如下:

1) 在残差网络中融入双向门控循环单元, 综合双向门控循环单元对于时间序列特征提取以及残差网络在解决网络退化和过拟合方面的优势, 建立数据驱动的超短期风电功率预测模型(data driven model, DDM), 将其预测结果作为模板。

2) 在大量历史风速-功率数据的基础上, 基于多项式-线性回归算法拟合风速-功率曲线, 建立反映风电场实际风速-功率转变特性的物理驱动模型(physical drive model, PDM)。通过深度双向循环残差神经网络对未来 4 h 内的数值天气预报(numerical weather prediction, NWP)进行修正, 修正风速经风速-功率曲线转换为预测功率。

3) 在验证集上设定风速突变阈值, 进一步建立 DDM 和 PDM 之间的切换触发机制, 将风速低于切入风速点的预测功率置零, 重构并输出预测功率曲线。对吉林某装机容量为 400.5 MW 的风电场提供的数据进行模拟实验, 以验证所提出模型的有效性和适用性。

1 超短期风电功率预测建模

1.1 数据驱动模型构建

1.1.1 残差网络

残差网络是深度学习框架中的一种新型网络结构, 该网络被发明的动机是解决随着网络深度增加随之而来的网络退化及过拟合问题。与减少数据规模、池化结构以及 dropout 策略相比, 残差网络结构解决该问题的优势是方便灵活, 不受数据规模干扰, 同时保持了模型训练过程中的数据流, 增强

了网络对价值信息的保护能力^[22-23]。

残差块结构如图 1 所示, 对于时间序列预测任务, 经典残差块的网络层由一维卷积神经网络(one-dimensional convolutional neural network, 1D-CNN)和激活函数(多为线性整流单元, rectified linear unit, ReLU)组成, 残差学习的思想是在网络中提供层间的连接捷径, 对于一个深度为 L 的网络, 输入输出映射表示如式(1)所示。

$$H(x') = f(x') \quad (1)$$

式中: $H(x')$ 为堆叠层的期望映射; $f(\cdot)$ 为网络层的映射函数; x' 为堆叠层 $L-1$ 的输出。对于残差网络结构, 第 L 个堆叠层的映射如式(2)所示。

$$H(x') = f(x') + x' \quad (2)$$

输入中加入 x' 意味着残差学习可以看作是前馈网络, 而传统的深度神经网络(deep neural network, DNN)只是 x' 和 H_L 之间的表达式。因此, 整个网络的目标是减少 $H_L - x'$ 。残差网络的最终输出表示为 $f_L(H_{L-1}) + f_{L-1}(H_{L-2}) + \dots + f_1(x') + x'$, 而卷积神经网络的输出为 $f_L(f_{L-1}(\dots(f(x'))))$, 表明残差网络可以在训练过程中保持输入流。

1.1.2 网络结构改进

为了增强网络对于时序特征的提取能力, 在残差网络中融入了双向门控循环单元(bi-directional gated recurrent neural, Bi-GRU)。Bi-GRU 在输入数据的时间维度以顺序和逆序依次进行特征提取, 并将每个 GRU 的输出拼接成为最终的输出层。使得各时间步的输出节点都包含输入序列在当前时刻过去和未来的上下文信息, 从而增强网络对时间数据的特征提取能力, 其中双向循环神经网络及 GRU 的原理可参考文献[23-24]。本文改进的网络结构基本块如图 2 所示, 其中网络的核心部分由若干个基本块堆叠而成, 每个基本块接受上一基本块的输入并提供下一基本块的输出, 同一标号的输入输出接口相连接。CONCAT 代表 Tensorflow 框架下的张量融合操作, 每一次特征处理后的结果在网络中进行全连接并输入到下一基本块, 保证数据在层间传递时不损失关键特征。

为提升训练阶段模型对数据关键特征的动态提取能力, 在输入数据张量的时间和空间通道融入注意力机制。设输入数据包含 m 个特征, 对于输入时间步 t , 其空间特征的注意力权重向量计算如式(3)所示。

$$e_t = \sigma(W_e x_t + b_e) \quad (3)$$

式中: e_t 代表各个特征的注意力权重向量; W_e 为权




图 1 残差块结构

Fig.1 Structure of residual block




图 2 网络基本块

Fig.2 Network base block

重矩阵; b_e 代表注意力权重向量的偏置向量; $\sigma(\cdot)$ 代表 Sigmoid 激活函数。

采用 Softmax 函数对 e_t 进行归一化, 得到各特征的归一化注意力权重矩阵 $\alpha_t = [\alpha'_1, \alpha'_2, \dots, \alpha'_m]$, 对于第 k 个特征, $k \in \{1, 2, \dots, m\}$, 其注意力权值计算如式(4)所示。

$$\alpha'_k = \frac{\exp(e'_k)}{\sum_{i=1}^m e'_i} \quad (4)$$

根据注意力权重计算方法, 得到输入特征向量 x_t 的加权特征向量 x'_t 。经空间注意力融合后的张量矩阵, 经过一个长短期记忆网络(long short term memory, LSTM)层并融入时间注意力权重模块, 将最终时空注意力融合张量矩阵输入到第 1 个基本块, 设输入时间序列的步长为 j , 其时间注意力权重 β_j 如式(5)所示。

$$\beta_j = F_{\text{ReLU}}(W_d h_j + b_d) \quad (5)$$

式中: $\beta_j = [\beta'_1, \beta'_2, \dots, \beta'_j]$; W_d 为神经网络权重矩阵; b_d 为时间注意力权重的偏置向量; $F_{\text{ReLU}}(\cdot)$ 表示线性

整流单元(rectified linear unit, ReLU)激活函数。

采用 Softmax 函数对 β_i 进行归一化, 得到归一化注意力权重矩阵 $\varepsilon_i = [\varepsilon_i^1, \varepsilon_i^2, \dots, \varepsilon_i^j]$, 将各时刻的注意力权重和隐含层神经元状态 h_i 进行加权, 得到时序信息状态 h'_i , 如式(6)、(7)所示。

$$\varepsilon_i^j = \frac{\exp(\beta_i^j)}{\sum_{l=1}^j \beta_i^l} \quad (6)$$

$$h'_i = \varepsilon_i \otimes h_i = \sum_{\tau=1}^j \varepsilon_i^{\tau} h_{\tau}^{\tau} \quad (7)$$

式中: $\otimes$ 代表矩阵乘积。

基于改进的网络结构构建预测器, 训练得到数据驱动超短期风电功率预测模型, 预测模式如图 3 所示。与传统滚动预测的输出模式不同, DDM 由多任务学习机制进行输出, 一次性输出未来 4 h 预测功率序列。输入特征矩阵描述如下, 由历史功率和预测时段对应数值天气预报提供的气象属性混合输入。设起报时刻为 t , 历史功率数据由 t 时刻及历史 15 个连续的时点构成的长度为 16 的向量构成, 气象特征由 $t+1$ 时刻及后续 15 个点构成的长为 16 的向量构成。经构建的人工智能模型进行映射后, 输出 $t+1$ 时刻到 $t+16$ 时刻的 16 点功率预测序列。

1.2 物理驱动模型构建

从狭义上来说, 物理驱动模型是通过建立数学模型模拟风电场风能资源分布以及风能资源到输出功率转化过程的预测方法^[25]。但从广义上说, 通过拟合风速-功率曲线(wind speed power curve, WPC)获取风电转换模型, 其决策机理透明, 满足风电场实际运行数据的统计特性, 也应该属于物理预测模型的范畴。基于此, 以风电场实测风速及实际功率为输入, 基于多项式-线性回归算法拟合 WPC, 构建物理驱动的风电功率预测模型。通过对预测域内的 NWP 风速进行修正, 从而获取预测时段的输入, 得到风电功率预测结果。

由于风速为 1 维时间序列, 通过一元线性回归拟合可能出现“翘尾”现象(即低风速测曲线上挑, 不在散点内侧), 无法反映 WPC 的实际走势。因此, 采用多项式回归将风速序列进行升维, 升维后的特征为风速的高次项表示。进一步采用多元线性回归拟合风速-功率曲线, 作为物理预测模型。设 x 为风速序列, $x^2, x^3, \dots, x^n$ 为风速序列经多项式回归后得到的高次表示, 多元线性回归原理如式(8)所示。

$$y = \beta_0 + \beta_1 x + \beta_2 x^2 + \dots + \beta_n x^n + \varepsilon \quad (8)$$




图 3 预测模式

Fig.3 Prediction pattern

式中: β_0 为常数项; n 为回归变量数量; $\beta_0 - \beta_n$ 代表偏回归系数, 表示在其他自变量保持不变时, $x_i (i=1, 2, \dots, n)$ 增加或减少一个单位时 y 的平均变化量; ε 为去除若干个自变量后对 y 造成影响而形成的随机误差(残差)。

WPC 拟合后, 将预测时段的修正风速特征输入到 WPC 得到预测功率, 将高风速波动时点数据用 WPC 的预测结果进行订正。

2 DDM 及 PDM 的切换机制及总体建模流程

在不考虑弃风限电及机组维护的前提下, 风速突变是功率突变的内因。由于技术水平限制, 当前 NWP 的精度仍然有待提高。对深度学习算法来说, 在未来 4 h 的预测域内, 随着预测步长的增加, 输入历史功率提供的价值信息量降低, 和预测域时间轴对应的 NWP 在一定程度上可以补充这一信息空档。由于 NWP 的精度限制, 特别是多步预测的预测曲线存在时移特性, 导致高波动时点的误差较高, 特别是极端低出力时段, 预测值被拉高, 在高预报时点更加严重^[26-27]。此外, 受时间序列的可预测性限制, 高波动时间段可预测性较差, 人工智能模型在处理突变型时间序列时误差较大, 而不受时间连续性限制的 WPC 可以解决这一问题, 且风电机组运行的惯性特性也可以保留在风速-功率曲线蕴含的统计特性中。因此考虑在高波动时点, 以实时的风速修正值输入到风速-功率曲线, 获取物理模型预测值对 DDM 的预测结果进行修正。对于极端低出力时点, 若修正风速低于切入风速, 则将出力值置零, 最后按时间轴方向重构预测序列。

本文提出的基于数据-物理混合驱动模型(data physics hybrid driven model, DPHDM)的超短期风电功率预测模型技术路线如图 4 所示, 其总体思路是根据风速波动阈值建立起 DDM 和 PDM 之间的动态切换机制, 发挥混合预测模型的优势。首先将




图4 技术路线图

Fig.4 Technology roadmap

DDM 的预测结果作为模板, 在高风速波动时点用 PDM 进行预测, 并对预测模板对应的预测值进行修改。对于修正风速小于切入风速的低出力情形, 将预测功率归零。详细步骤及技术路线如下:

1) 搭建双向循环深度残差网络, 以 170 m、100 m、30 m 高度的 NWP 风速、温度、动量通量以及历史实测功率作为输入, 训练得到数据驱动的超短期风电功率预测模型, 并将其预测结果作为模板。

2) 对风电场实测风速进行异常处理, 双向循环深度残差网络作为修正器, 以 170 m、100 m、30 m 高度的 NWP 风速, 风电场历史实测风速作为输入, 订正未来 4 h 内的预报风速。

3) 基于多项式回归算法对风速序列进行升维, 进一步采用多元线性回归算法拟合 WPC, 作为物理预测模型。

4) 采用式(9)来刻画高波动时点的风速波动, 设定风速波动阈值, 建立 DDM 和 PDM 之间的切换机制。

$$f_{ws}(i) = \frac{s_i^3 - s_{i-1}^3}{s_{i-1}^3} \quad (9)$$

式中: s_i 代表 i 时点的修正风速。

5) 将风速低于切入风速的样本视为极端低出力样本, 将预测结果置零, 并在模板中进行替换, 重构预测结果并输出。

3 实验分析

3.1 数据描述及评价指标

采用吉林省某装机容量为 400.5 MW 的风电场提供的数据进行仿真实验分析, 数据包括 2018 年 1 月 1 日—12 月 31 日的实测风速数据、NWP 及实测功率数据, 数据分辨率为 15 min, 切入风速为 3.5 m/s。1—8 月的数据作为训练集, 9、10 月的数据作为验证集, 11、12 月的数据作为测试集。其中计算机参数为 { 处理器: Intel(R) Core(TM) i5-7300HQ CPU @ 2.50GHz; 内存: 16 GB }, 长 Bi_GRU 包含 32 个神经元, 短 Bi_GRU 包含 16 个神经元, 1D_CNN 卷积核数量为 3, 卷积核尺寸为 1, 激活函数为 ReLU 激活函数, 模型共级联了 7 个基本块, 经全连接网络直接映射 16 步的超短期功率预测输出, 数据驱动模型的训练参数如表 1 所示。

为了防止过拟合, 提升训练效率, 训练阶段采用了模型训练提前停止策略, 即当连续 5 次训练损失不再下降时停止训练。

文中采用归一化均方根误差(normalized root mean square error, NRMSE)、归一化平均绝对误差(normalized mean absolute error, NMAE)、 R_{NMAE} 和相关系数 3 个指标对提出的超短期风电功率预测模型的性能进行评估。

R_{NRMSE} 用于评估误差的离散程度, 值越接近于

0 越好, 计算式如式(10)所示。

$$R_{\text{NRMSE}} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{nP_{\text{cap}}^2}} \quad (10)$$

式中: y_i 代表 i 时刻的实际功率; $\hat{y}_i$ 代表 i 时刻的预测功率; n 代表测试集长度; P_{cap} 代表实际风电场开机容量, 由于实际风电场开机容量难以获取, 本文以装机容量代替。

R_{NMAE} 用于评估误差平均分布情况, 值越接近 0 越好, 计算式如式(11)所示。

$$R_{\text{NMAE}} = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i| \times 100\%}{P_{\text{cap}}} \quad (11)$$

相关系数 I 的计算式如式(12)所示。

$$I = \frac{\text{cov}(y, \hat{y})}{\sqrt{D(y) \cdot D(\hat{y})}} \quad (12)$$

式中: $\text{cov}(\cdot)$ 代表协方差; $D(\cdot)$ 代表方差。

为了统一量纲, 提升计算效率, 采用最大-最小归一化方法对输入、输出数据进行归一化处理, 以某个输入特征 x_{inp} 为例, 归一化原理如式(13)所示。

$$x' = \frac{x_{\text{inp}} - x_{\min}}{x_{\max} - x_{\min}} \quad (13)$$

式中: x' 代表归一化后的特征; $x_{\min}$ 和 $x_{\max}$ 分别代表 x_{inp} 的最大值和最小值。预测阶段, 依据反归一化公式将预测结果还原到原始功率区间, 反归一化原理如式(14)所示。

$$x_{\text{ori}} = x'(x_{\max} - x_{\min}) + x_{\min} \quad (14)$$

3.2 预测性能分析


模型的空间和时间注意力权重如图 5 所示。其中, 空间注意力权重最高的是历史功率, 在超短期预测的时间尺度内, 风速的不可突变性使得风电功率序列的自相关性成为保障预测精度的重要因素之一。其次是动量通量, 其代表了流体在传播过程中单位面积所携带的能量, 在一定程度上表征了风和风机扇叶能量交互的大小。接下来是 100 m、30 m、170 m 高度的风速, 因是 NWP 提供的风速序列, 故预测精度的限制使其未在模型决策时发挥了重要作用。空间注意力权重最低的是气温, 因其和风电功率无直接因果关系, 故在模型决策时贡献最小。时间注意力权重在输入步长大于 3 之后逐渐升高, 即距离预测时点越近, 对模型决策的贡献越高。输入步长 1 和 2 由于距离预测域过远, 因此其注意力权重同样较低。

采用多项式回归将风速序列升到 3 维, 进一步基于多元线性回归算法拟合风速-功率曲线, 风速-功率曲线拟合结果如图 6 所示, 拟合的曲线分布在风速-功率散点正中间, 拟合效果较好。


在 9、10 月份的验证集上对风速波动阈值进行分析并设定, 以 10% 作为风速波动的取值步长, 在 0~100 之间取点试验, 评价指标为第 16 步预测的

表 1 训练参数

Table 1 Training parameters				
模型	epoch	batch_size	learning_rate	dropout
DDM	50	128	0.01	0.2



(a) 空间注意力权重



(b) 时间注意力权重

图 5 训练集时空注意力权重分布

Fig.5 Spatial-temporal attention set weight distribution of training set

R_{NRMSE} 指标。如图 7 所示, 当阈值设定为 100 时, 代表仅应用 DDM 进行预测, 当阈值设定为 0 时, 仅采用 PDM 进行预测。其中仅应用 PDM 预测的误差最高, 当切换阈值为 30% 时, 预测误差最低, 因此将 30% 作为风速波动切换阈值, 以此作为 DDM 和 PDM 之间的切换法则。

DPHDM 和 DDM 模型的 R_{NRMSE} 如表 2 所示,

总体来说,DDM 经与 PDM 切换输出后,预测误差可有效降低,但是随着预测步长的增加,预测误差的降低程度有所下降。这是因为随着预测步长的增加,风速修正的精度下降,误切换的概率增大。到预测的第 16 步,DPHDM 的性能较差,在 12 月份由于风速波动较大,其预测精度略低于 DDM。但总体来说,DPHDM 的性能优于 DDM。值得说明的是,由于风机数量较大,风速的空间分散性导致了风电场历史平均风速难以对风电场的风速波动进行精准表征,因此预测精度上限较低。

DPHDM 的 R_{NMAE} 及相关系数如图 8 所示,和传统的多步预测模型一样,随着预测步长的增加, R_{NMAE} 呈现明显的上升趋势,相关系数呈现明显的下降趋势。但是在 2 个月的长考核期下,对于未来第 16 步的预测, R_{NMAE} 维持仍低于装机容量的 15%,相关系数高于 70%。按照文献[17]的描述,未来第 16 步的预测曲线和实际曲线呈显著相关。

在测试集的第 659 个样本及第 2 683 个样本的预测曲线上进行性能分析,如图 9 所示。其中样本

659 的第 4、5、6、7 步预测发生了向下切换,且切换后误差降低。样本 2683 的第 2、3、4、5 步预测发生了向下切换,切换后预测曲线更接近实际曲线。此类切换被定义为有利切换。

以样本 614 和样本 1578 为例,对极端低出力的切换性能进行分析,如图 10 所示。其中样本 614

表 2 DPHDM 和 DDM 的 R_{NRMSE} 对比

月份		不同预测步长下的 R_{NRMSE}				
		1	4	8	12	16
11	DPHDM	0.037 9	0.070 0	0.109 1	0.131 1	0.149 2
	DDM	0.048 1	0.180 2	0.118 4	0.138 0	0.149 1
12	DPHDM	0.034 1	0.084 3	0.122 0	0.146 7	0.167 8
	DDM	0.041 7	0.092 4	0.130 1	0.153 1	0.167 6




图 8 DPHDM 的 R_{NMAE} 及相关系数指标

Fig.8 R_{NMAE} and correlation coefficient indexes of DPHDM





图 9 有利切换样本分析

Fig.9 Favorable switching sample analysis




图 6 风电场风速-功率曲线

Fig.6 Wind speed-power curve of wind farm




图 7 不同切换阈值下的误差分布

Fig.7 Error distribution under different switching thresholds




图 10 低出力修正样本分析
Fig.10 Analysis of low output modified sample

的所有时点出力均为 0, 即风速低于风机切入风速。在第 1—15 个时点, 修正后的风速可以有效映射低出力情形, 因此预测曲线被拉低到 0 出力。样本 1578 的 1—10 步发生低出力转换, 且转换后的预测曲线和实际功率曲线更相符。

测试集上将几种数据驱动模型的建模策略和本文的 DPHDM 性能进行对比分析, 评估指标为 R_{NRMSE} 。策略 1: 采用集成学习算法中的 XgBoost 算法进行建模; 策略 2: 采用 CNN_LSTM 算法进行建模; 策略 3: 采用 Seq2Seq 算法(循环神经网络组成的编-解码结构)进行建模, 以 GRU 为基本循环神经单元; 策略 4: 将本文模型的 GRU 替换为 LSTM 进行建模。其中参与对比的循环神经网络均包含 16 个神经元, CNN 包含的卷积核数量为 32, 卷积核大小为 1, 第 4、8、12、16 步的 R_{NRMSE} 指标对比如表 3 所示。

与其他预测模型相比, 本文模型可以获得最低的预测误差, 双向循环网络和残差网络的结合可以有效提升超短期风电功率预测精度, 集成学习模型和传统的深度学习模型取得了相似结果, 这也说明了对于超短期风电功率预测, 单纯的人工智能算法预测可能存在进度瓶颈, 而组合预测模型可以有效提升预测精度。双向循环神经网络采用 GRU 结构与采用 LSTM 结构相比, 在不同的预测步长上都

表 3 不同模型 R_{NRMSE} 指标对比

Table 3 Comparison of R_{NRMSE} indexes of different models

模型	不同预测步长下的 R_{NRMSE}			
	4	8	12	16
策略 1	0.105 1	0.129 1	0.166 1	0.186 1
策略 2	0.103 9	0.127 0	0.164 0	0.184 5
策略 3	0.103 4	0.128 2	0.167 0	0.187 6
策略 4	0.080 1	0.119 4	0.144 3	0.160 9
本文模型	0.077 2	0.116 7	0.137 9	0.158 9

具有一定的优势。

由于风速修正同样存在误差, 因此存在因误切换导致的 DPHDM 预测曲线相比 DDM 的预测曲线更加偏离实际曲线的情况, 如图 11 所示。以第 298 个样本和第 2 010 个样本为例, 分析误切换产生的原因以及实际影响。由于预测风速低于切入风速, 因此样本 298 的 1—7 步发生了低出力切换, 但由于修正风速低于实际值, 使得低出力转换有误。由于样本 2010 的修正风速高于实际风速, 因此在高波动时点发生了向上误切换。经计算, 测试集共包含 5 761 个样本, 其中有 689 个样本发生了切换或者低出力转换, 占比为 11.95%, 包含误切换样本 63 个, 占比为 9.14%, 因此可以判定通过建立 DDM 和 PDM 的切换机制可以有效提升预测精度。

关于 DPHDM 起反作用的可能原因分析如下:

- 1) 风电场自身设备故障或故障修复后重新启动, 使整场出力与风特性不相符。
- 2) 风电场存在弃风限电情况, 打破了实际风速-功率转换的规律性。
- 3) 风速修正后仍然存在误差, 当修正风速波动趋势预测有误时会产生误切换情况。

4 结论

论文提出一种数据物理混合驱动的超短期风电功率预测模型, 得到的主要结论如下:

- 1) DDM 模型通过引入时间和空间注意力机制, 使得模型注重对关键信息的提取, 增加了训练精度。PDM 模型通过风速-功率转换特性, 基于多项式-线性回归算法建立风速-功率曲线。
- 2) DPHDM 实现了 PDM 和 DDM 之间的协调自动切换, 与 DDM 模型相比, DPHDM 模型的预测误差存在明显的下降, 测试集第 16 步预测的 R_{NRMSE} 为 0.158 9。对于极端低出力样本, 预测值可以有效拉低。




图 11 误切换样本分析

Fig.11 Error switching sample analysis

3) 受风速修正精度的限制, DPHDM 模型存在误切换的情形, 经统计误切换的占比为 9.14%, 因此 DPHDM 模型可以稳定提升预测精度。

下一步将进一步研究随季节变换的动态切换机制, 以使 DPHDM 能够随着季节的变化自适应设定切换阈值, 以更加精细地实现模型之间的切换, 降低误切换的占比。

参考文献 References

- [1] 王渝红, 史云翔, 周旭, 等. 基于时间模式注意力机制的 BiLSTM 多风电机组超短期功率预测[J]. 高电压技术, 2022, 48(5): 1884-1892.
WANG Yuhong, SHI Yunxiang, ZHOU Xu, et al. Ultra-short-term power prediction for BiLSTM multi wind turbines based on temporal pattern attention[J]. High Voltage Engineering, 2022, 48(5): 1884-1892.
- [2] 杨茂, 刘慧宇, 孙勇, 等. 基于原子稀疏分解和支持向量机的风电功率实时预测研究[J]. 东北电力大学学报, 2020, 40(3): 1-7.
YANG Mao, LIU Huiyu, SUN Yong, et al. A study on real-time prediction of wind power based on atomic sparse decomposition and support vector machine[J]. Journal of Northeast Electric Power University, 2020, 40(3): 1-7.
- [3] 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.
- [4] 崔杨, 王议坚, 黄彦浩, 等. 基于多元注意力框架与引导式监督学习的闭环风电功率超短期预测策略[J]. 中国电机工程学报, 2023, 43(4): 1334-1346.
CUI Yang, WANG Yijian, HUANG Yanhao, et al. Closed-loop wind power ultra-short-term forecasting strategy based on multi-attention framework and guided supervised learning[J]. Proceedings of the CSEE, 2023, 43(4): 1334-1346.
- [5] YANG M, SHI C Y, LIU H Y. Day-ahead wind power forecasting based on the clustering of equivalent power curves[J]. Energy, 2021, 218: 119515.
- [6] 牛东晓, 纪会争. 风电功率物理预测模型引入误差量化分析方法[J]. 电力系统自动化, 2020, 44(8): 57-65.
NIU Dongxiao, JI Huizheng. Quantitative analysis method for errors introduced by physical prediction model of wind power[J]. Automation of Electric Power Systems, 2020, 44(8): 57-65.
- [7] 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): 3455-3462.
MIAO Changxin, WANG Xia, LI Hao, et al. Day-ahead prediction of wind power based on NWP wind speed error correction[J]. Power System Technology, 2022, 46(9): 3455-3462.
- [8] 马伟, 乔颖, 鲁宗相, 等. 基于敏感气象特征因子筛选与优化组合的短期风电功率预测[J]. 电网技术, 2023, 47(7): 2897-2908.
MA Wei, QIAO Ying, LU Zongxiang, et al. Short-term wind power prediction based on combination of screening and optimizing sensitive meteorological characteristics[J]. Power System Technology, 2023, 47(7): 2897-2908.
- [9] 赵永宁. 基于时空相关性的大规模风电功率短期预测方法研究[D]. 北京: 中国农业大学, 2019.
ZHAO Yongning. Research on short-term large-scale wind power forecasting methods based on spatio-temporal correlation[D]. Beijing, China: China Agricultural University, 2019.
- [10] KARINIOTAKIS G N, STAVRAKAKIS G S, NOGARET E F. Wind power forecasting using advanced neural networks models[J]. IEEE Transactions on Energy Conversion, 1996, 11(4): 762-767.
- [11] 甄成刚, 郭东庆, 牛海明. 基于 DLCEEMDAN-SA-TCN 和误差修正的短期风电功率预测[J]. 电力信息与通信技术, 2022, 20(5): 38-46.
ZHEN Chenggang, GUO Dongqing, NIU Haiming. Short term wind power prediction based on DLCEEMDAN-SA-TCN and error correc-

- tion[J]. Electric Power Information and Communication Technology, 2022, 20(5): 38-46.
- [12] YUAN X H, CHEN C, YUAN Y B, et al. Short-term wind power prediction based on LSSVM-GSA model[J]. Energy Conversion and Management, 2015, 101: 393-401.
- [13] 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.
- [14] 孟安波, 陈 顺, 王陈恩, 等. 基于混沌 CSO 优化时序注意力 GRU 模型的超短期风电功率预测[J]. 电网技术, 2021, 45(12): 4692-4700.
MENG Anbo, CHEN Shun, WANG Chen'en, et al. Ultra-short-term wind power prediction based on chaotic CSO optimized temporal attention GRU model[J]. Power System Technology, 2021, 45(12): 4692-4700.
- [15] 曾 亮, 雷舒敏, 王珊珊, 等. 基于 OVMD-SSA-DELM-GM 模型的超短期风电功率预测方法[J]. 电网技术, 2021, 45(12): 4701-4710.
ZENG Liang, LEI Shumin, WANG Shanshan, et al. Ultra-short-term wind power prediction based on OVMD-SSA-DELM-GM model[J]. Power System Technology, 2021, 45(12): 4701-4710.
- [16] 李 青, 张新燕, 马天娇, 等. 基于 ECBO-VMD-WKELM 的风电功率超短期多步预测[J]. 电网技术, 2021, 45(8): 3070-3078.
LI Qing, ZHANG Xinyan, MA Tianjiao, et al. Multi-step ahead ultra-short term forecasting of wind power based on ECBO-VMD-WKELM[J]. Power System Technology, 2021, 45(8): 3070-3078.
- [17] 丁婷婷, 杨 明, 于一潇, 等. 基于误差修正的短期风电功率集成预测方法[J]. 高电压技术, 2022, 48(2): 488-496.
DING Tingting, YANG Ming, YU Yixiao, et al. Short-term wind power integration prediction method based on error correction[J]. High Voltage Engineering, 2022, 48(2): 488-496.
- [18] 茆美琴, 曹 雨, 周松林. 基于误差叠加修正的改进短期风电功率预测方法[J]. 电力系统自动化, 2013, 37(23): 34-38.
MAO Meiqin, CAO Yu, ZHOU Songlin. Improved short-term wind power forecasting method based on accumulative error correction[J]. Automation of Electric Power Systems, 2013, 37(23): 34-38.
- [19] 刘 纯, 范高峰, 王伟胜, 等. 风电场输出功率的组合预测模型[J]. 电网技术, 2009, 33(13): 74-79.
LIU Chun, FAN Gaofeng, WANG Weisheng, et al. A combination forecasting model for wind farm output power[J]. Power System Technology, 2009, 33(13): 74-79.
- [20] HAN S, LIU Y Q. The study of wind power combination prediction[C]//Proceedings of 2010 Asia-Pacific Power and Energy Engineering Conference. Chengdu, China: IEEE, 2010: 1-4.
- [21] LI G, SHI J, ZHOU J Y. Bayesian adaptive combination of short-term wind speed forecasts from neural network models[J]. Renewable Energy, 2011, 36(1): 352-359.
- [22] 张淑清, 杜灵韵, 王册浩, 等. 基于格拉姆角场与改进 CNN-ResNet 的风电功率预测方法[J]. 电网技术, 2023, 47(4): 1540-1547.
ZHANG Shuqing, DU Lingyun, WANG Cehao, et al. Wind power forecasting method based on GAF and improved CNN-ResNet[J]. Power System Technology, 2023, 47(4): 1540-1547.
- [23] KO M S, LEE K, KIM J K, et al. Deep concatenated residual network with bidirectional LSTM for one-hour-ahead wind power forecasting[J]. IEEE Transactions on Sustainable Energy, 2021, 12(2): 1321-1335.
- [24] 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.
- [25] 杨 茂, 代博祉, 刘 蕾. 风电功率概率预测研究综述[J]. 东北电力大学学报, 2020, 40(2): 1-6.
YANG Mao, DAI Bozhi, LIU Lei. A Review of wind power probabilistic prediction[J]. Journal of Northeast Electric Power University, 2020, 40(2): 1-6.
- [26] 董 雪, 赵宏伟, 赵生校, 等. 基于二次分解和多目标优化的超短期海上风电功率预测[J]. 高电压技术, 2022, 48(8): 3260-3270.
DONG Xue, ZHAO Hongwei, ZHAO Shengxiao, et al. Ultra-short-term offshore wind power forecasting based on secondary decomposition and multi-objective optimization[J]. High Voltage Engineering, 2022, 48(8): 3260-3270.
- [27] 杨 茂, 于欣楠. 考虑风电场功率爬坡的超短期组合预测[J]. 东北电力大学学报, 2022, 42(1): 63-70.
YANG Mao, YU Xinnan. An ultra-short term combined prediction considering wind farm power climbing[J]. Journal of Northeast Electric Power University, 2022, 42(1): 63-70.



YANG Mao
Ph.D., Professor



WANG Da
Ph.D. candidate
Corresponding author

杨 茂

1982—, 男, 博士, 教授, 博导
主要研究方向为电力系统稳定分析与新能源并网
E-mail: yangmao820@163.com

王 达(通信作者)

1995—, 男, 博士生
主要研究方向为新能源功率预测
Email: 1610909212@qq.com

收稿日期 2023-03-18 修回日期 2023-09-28 编辑 何秋萍