

考虑风速分段控制和功率连续演化的 短期风电功率预测

李丹¹, 黄烽云¹, 缪书唯², 唐建³, 罗娇娇³

(1. 三峡大学电气与新能源学院, 湖北省 宜昌市 443002;

2. 梯级水电站运行与控制湖北省重点实验室(三峡大学), 湖北省 宜昌市 443002;

3. 新能源微电网湖北省协同创新中心(三峡大学), 湖北省 宜昌市 443002)

Short-term Wind Power Forecasting Considering Wind Speed Piecewise Control Strategy and Power Continuous Evolution Mechanism

LI Dan¹, HUANG Fengyun¹, MIAO Shuwei², TANG Jian³, LUO Jiaojiao³

(1. Electric and New Energy Faculty, China Three Gorges University, Yichang 443002, Hubei Province, China;

2. Hubei Provincial Key Laboratory for Operation and Control of Cascaded Hydropower Station (China Three Gorges University)
Yichang 443002, Hubei Province, China;

3. Hubei Provincial Collaborative Innovation Center for New Energy Microgrid (China Three Gorges University),
Yichang 443002, Hubei Province, China)

ABSTRACT: The current forecasting models for wind power time series have limitations in handling irregularly sampled time series and need to pay more attention to the piecewise control characteristics of wind speed on wind power output. To address these issues, this paper proposes a short-term wind power forecasting method based on a piecewise controlled hybrid differential neural network. First, the wind speeds at discrete timesteps are converted into a continuous path using cubic spline interpolation. The hybrid differential neural network is employed to model the temporal inertia of wind power and the regulatory effects of continuous wind speed on wind power, thereby capturing its dynamic evolution process in full. Then, based on the differentiated control modes for wind power output when wind speed falls into different numerical intervals, a multilayer perceptron is employed to dynamically output continuous weighting values representing the affiliation of wind speed to distinct control intervals. Finally, the short-term power forecasts for the wind farm are output, which can simultaneously satisfy the temporal inertia of wind power and the piecewise controlling patterns of wind speed. Practical case studies demonstrate that this method exhibits significant advantages in handling irregularly sampled time series, with the proposed piecewise control hybrid differential neural network outperforming the popular RNN networks in terms of forecasting accuracy and reliability.

KEY WORDS: short-term wind power forecasting; time series; neural control differential equations; gate control function; piecewise control

摘要: 当前风电功率时序预测模型将时间均匀离散化处理, 忽略了风电功率连续演化和风速对风电功率的分段控制特性。为提高预测的合理性, 并拓展针对输入时间序列不规则时间间隔采样场景的应用, 提出一种基于分段控制混合微分神经网络的短期风电功率预测方法。首先, 通过三次样条插值将离散时间点的风速连续化为风速时序轨迹, 利用混合微分神经网络并行模拟时间惯性和连续风速影响下的风电功率控制演化规律, 以完整反映其动态演变模式; 然后, 依据风速落入不同数值区间时对风电功率的差异化控制模式, 采用多层感知器动态输出风速隶属于不同控制区间的连续值权重; 最后, 输出同时满足时间惯性和风速分段控制演化规律的风电场功率短期预测值。实际算例结果表明, 该方法在处理不规则采样时间序列方面表现出显著优势, 分段控制混合微分神经网络在预测精度和可信度上优于常见 RNN 网络。

关键词: 短期风电功率预测; 时间序列; 神经控制微分方程; 门控函数; 分段控制

DOI: 10.13335/j.1000-3673.pst.2025.0365

0 引言

近年来, 以风电为代表的新能源发电在能源结构占比逐渐增大^[1]。精准的风电功率预测可有效降低风电随机性和波动性影响, 为电力系统调度运行和优化决策提供重要依据^[2-3]。

基金项目: 国家自然科学基金项目(51807109)。

Project Supported by National Natural Science Foundation of China (51807109).

目前,针对未来 4~72 h 短期风电功率预测的主流思路是捕捉风电功率自身的时序演化规律,并利用风电功率与风速等主要影响因素之间的因果关系^[4-6]建立非线性映射模型。输入特征通常包括历史风电功率和数值天气预报(numeric weather prediction, NWP)提供的风速、风向等天气特征。考虑到实际影响因素复杂多变,当前主流方法是建立数据驱动的深度学习风电功率预测模型,其中以长短期记忆神经网络(long-short term memory neural network, LSTM)和门控循环单元神经网络(gated recurrent unit neural network, GRU)为代表的循环神经网络(recurrent neural network, RNN)应用最为广泛。大量研究以 RNN 网络为基础结合优化和时序分解技术提高风电预测的准确性和鲁棒性^[7-8],在处理输入特征时,将连续的时间轴离散化,通过建立并学习离散时间点数据之间的时间依赖关系,实现对目标时刻风电功率的预测^[9]。这一工作机制可行的前提是所有时序数据的时间间隔一致且均匀。然而,在实际工作中,由于不同参数的采样间隔可能存在差异,且因传感器故障、数据传输异常等引起的短时数据缺失无法避免,数据采样时间的一致性和均匀性难以完全保证,限制了传统 RNN 网络在采样时间不规则时序场景的直接应用。

为了在采样时间不规则时序场景中应用 RNN 预测模型,一种常见解决方法是在数据预处理阶段利用插值技术转化为等间隔时序数据的形式^[10]。然而,数据插值过程往往与预测过程独立,它们之间难以双向协调^[11],无法保证目标效果的一致性。同时,在面对高缺失率或连续缺失的风电数据时,均匀时间间隔插补法可能引入高额偏差,工作量大且效果不佳^[12]。相比之下,更优的解决方案是将时序不规则信息直接引入预测模型。例如,文献[13]在标准 GRU 模型中引入观测值之间的时间差额输入,动态更新隐状态,为 RNN 模型捕获不规则采样间隔下的时序依赖关系提供可能。为反映先前状态影响随时间间隔延长会逐渐减弱这一客观规律,文献[14]引入衰减函数,根据时间间隔的长短对隐状态进行动态加权,使其更灵活地反映不同长度的时间间隔下输入特征对预测结果的影响,提高模型对不规则采样数据的适应能力。尽管如此,这些针对时间间隔的处理方法仅局限于利用邻近观测值信息,难以捕捉序列的全局特征^[10]。而且,这些方法都建立在离散时间点的时间序列基础上,时间本质上是连续的,状态随时间的变化也应是连续的,若始终针对离散时间序列,可能因无法捕捉状态变量连续变化

的细节而限制预测精度。

针对以上问题,受微分方程启发的神经微分方程(neural differential equations, NDE)模型应运而生,它将输入数据在时间轴上连续化为轨迹曲线,其预测过程基于动态系统的连续时变规律推演,无需对输入数据进行时间等间隔和离散化,避免了引入额外误差。作为 NDE 类模型的代表之一,神经常微分方程(neural ordinary differential equations, NODE)使用神经网络参数化隐状态的导数^[15],从初始条件出发推演后续隐状态轨迹,通过输出层映射得到目标时刻的输出。这种推演机制可摆脱预测模型对观测值采样一致性和均匀性的依赖。然而,若将 NODE 直接用于时序预测任务,大量数值积分将导致计算复杂度激增。对此,文献[16]提出 ODE-RNN 模型平衡运算效率与可行性,只有当检测到缺失值时,才采用 NODE 替代 RNN 单元推演数据缺失时刻的隐状态。然而, NODE 的设计机制仅考虑变量自身的连续演化,无法计及外部因素对目标变量时序演化过程的控制作用。

为计及外部因素的控制作用,神经控制微分方程(neural controlled differential equations, NCDE)模型在 NODE 模型的基础上加以改进,通过拟合外部控制变量的时序轨迹来控制目标变量的连续时间演化过程^[10]。这一突破性的研究很快受到广泛关注^[17-19]。文献[17]突破传统 NCDE 中要求控制量为预先观测量的限制,将其应用于在线预测。文献[18]在 NCDE 模型中引入注意力机制,实现多变量时间序列的分类和预测任务。文献[19]则将图卷积技术引入 NCDE 模型,通过双层机制实现时空特征提取。NCDE 模型对目标变量时序控制演化模式的推演,契合风速控制风电功率时序变化的特点,适合将其用于风电功率预测任务。然而,仅采用单一的 NCDE 模型或 NODE 模型,无法同时兼顾风速对风功率的影响机制和风电功率自身的时序规律,需要构建能融合两者优势的混合模型。

此外,使用 NDE 类模型进行风电功率预测时,需要考虑不同风速区间内风功率控制模式的差异性^[20]。并非全部值域区间的风速动态变化都会引起风机出力的动态响应,例如当实际风速低于切入风速或高于切出风速时,风机出力为零;当风速位于额定风速与切出风速之间时,风电出力始终维持额定值。由于风速的强波动性和气象环境的不确定性,风速对功率的控制模式可能动态切换,控制区间之间的风速分界点不能仅依据经验或标准风能转化曲线固定划分^[21]。然而,当前大多数研究仅在

输出层采用特定激活函数, 强行将预测功率压缩至 $[0,1]$ 的归一化区间, 不仅未充分利用风能转化机理, 而且忽略了风速控制区间划分的灵活性。

综合以上分析, 本文提出一种新颖的分段控制混合微分神经网络 (neural piecewise hybrid differential equation, NPHDE), 用于短期风电功率预测, 其主要特点和贡献如下:

1) 时间连续化与数值积分推演: 将神经微分方程技术引入短期风电功率预测, 通过时间连续化建立相邻时刻风电隐藏特征之间的数值积分推演关系, 为不规则采样条件下的风电功率时序预测提供一种全新解决方案。

2) 连续演化与动态控制相结合: 将 NODE 的时间演化机制与 NCDE 的控制演化机制相结合, 使预测模型可同时挖掘风功率自身时序演化规律和风速对风电功率的动态非线性控制关系。

3) 分段控制策略: 自适应分配风速落入各控制模式区间的隶属度权重, 并针对不同控制区间引入风速-功率的差异化分段控制策略, 提高 NPHDE 模型适应风速变化的灵活性和预测结果的合理性。

1 RNN 模型和神经微分方程模型

本节介绍循环神经网络模型(RNN)、神经微分方程模型(NDE)中的神经微分方程模型(NODE)和神经控制微分方程模型(NCDE)的基本形式和内在差异, 阐明设计神经混合微分方程模型(neural hybrid differential equation, NHDE)的必要性。

1.1 RNN 模型和 NDE 模型

RNN 通过拟合时间序列前后离散时间点隐状态 $z(t_0)$ 和 $z(t_1)$ 之间的非线性映射关系, 构建一个动态系统^[15], 其数学表达式为

$$z(t_1) = z(t_0) + f(z(t_0); \theta) \quad (1)$$

式中: $f(z(t_0); \theta)$ 为隐状态变化量, 可通过带门控机制的神经网络学习; θ 为待学习的网络参数。

式(1)可看作离散过程的迭代更新, 当 t_0 和 t_1 这两个时刻无限接近时, 迭代更新步长趋近于 0, 其连续化表征可近似为如下微分方程形式:

$$\frac{dz(t)}{dt} = f(z(t), \theta) \quad (2)$$

当采用神经网络学习以上微分项就构成了神经微分方程模型(NDE)。图 1 直观展示了 RNN 与 NDE 模型在隐状态更新过程中的区别。其中黑点表示隐特征在离散时间点上的状态, 各条黑线代表各个隐特征对应的状态时变轨迹。图 1(a)中 RNN 模型的隐状态仅在离散时间点处进行有限的非连续




图 1 RNN 与 NDE 模型隐状态更新机制对比

Fig. 1 Comparison of update mechanism of hidden state between RNN and NDE models

更新; 而图 1(b)中 NDE 模型通过微分项定义了连续更新的向量场, 以描述隐状态的连续演化过程。因此, 相较 RNN 的间断式更新, NDE 更适合描述动态系统的连续时间演变。

1.2 NODE 模型和 NCDE 模型

根据控制变量的不同, NDE 类模型可分为神经常微分方程模型(NODE)和神经控制微分方程模型(NCDE)两类。

NODE 从初始值 $z(t_0)$ 出发, 由时间变量 t 控制后续隐状态的时序轨迹^[15]:

$$z(t_1) = z(t_0) + \int_{t_0}^{t_1} f(z(t); \theta) dt \quad (3)$$

NCDE 模型则假设时间序列受外部输入 $X(t)$ 的控制^[10]:

$$z(t_1) = z(t_0) + \int_{t_0}^{t_1} f(z(t); \theta) dX(t) = z(t_0) + \int_{t_0}^{t_1} f(z(t); \theta) \frac{dX(t)}{dt} dt \quad (4)$$

当 $X(t)$ 为时间 t 时, NCDE 模型退化为 NODE。

图 2 展示了 NODE 与 NCDE 模型在隐状态更新过程中的差异。在图 2(a)所示的 NODE 模型中, 每个观测时间点处的隐状态由观测值进行更新, 相邻观测时间点之间的隐状态则通过 ODE 连续演化。然而, 一旦模型参数 θ 确定, 相邻观测时间点之间的演化就完全由初始状态和时间变量 t 决定, 隐状态可能在观测时间点前后出现断续^[22]。相比之下, 图 2(b)所示的 NCDE 模型通过观测值构造的连续轨迹 $X(t)$ 控制隐状态的更新, 使得隐状态 $z(t)$ 轨迹连续, 因此能够在相邻观测时间段内根据观测数据动态调整其内部状态。

从上述分析可以看出, NODE 模型是 RNN 在时间维上的连续化表征, 可精细捕捉时间序列内在的动态变化, 而 NCDE 更善于捕捉观测值输入与目标变量之间的动态控制关系。在风电功率预测中,




图2 NODE与NCDE模型隐状态更新机制的对比
Fig. 2 Comparison of hidden state update mechanism between NODE and NCDE models

为同时计及风功率时间序列内在动态特性和风速控制因素的影响,有必要综合 NODE 和 NCDE 优势,设计一种神经混合微分方程(NHDE)模型。

2 基于分段控制混合微分神经网络的短期风电功率预测

2.1 总体预测框架

图3展示了分段控制混合微分神经网络(NPHDE)的总体框架,它由神经混合微分方程(NHDE)和风速分段控制模块组成。

给定一组 n 个时间点的离散风速时间序列 $\{(x_i, t_i)\}_{i=1}^n$, 在输入层通过三次样条插值将其连续化为风速控制轨迹 $X(t)$, 并以三次多项式风速轨迹系数的形式并行输入 NHDE 模型和风速分段控制模

块中进行双线程处理:

1) NHDE 模型: 负责拟合受风速控制的风电功率时序演变规律。经过积分计算、维度映射等操作,从初始值 $z(t_0)$ 出发,由 $X(t)$ 和时间变量 t 控制生成风电功率隐特征轨迹 $z(t)$, 与 $X(t)$ 一起离散化处理后,经过两层全连接网络得到风电功率初始预测序列 $o(t)$ 。

2) 风速分段控制模块: 负责控制风速对风电功率差异化影响权重。风速轨迹 $X(t)$ 通过多层感知器输出预测时刻 t 对应的权重向量序列 $\{w_{i,t}, i=1,2,3,4\}$, 分别表示 t 时刻风速落入 4 种控制模式区间的权重得分。

最后,将初始预测功率序列 $o(t)$ 与固定功率输出(额定值或 0)按权重集成,经输出层映射得到预测时间段的风电功率预测曲线 $\hat{y}(t)$ 。

2.2 神经混合微分方程 NHDE

2.2.1 基本形式

在风电功率预测任务中,捕捉风电功率的动态演变规律至关重要。本文提出的 NHDE 模型通过拟合风电功率隐特征轨迹 $z(t)$ 与风速时序轨迹 $X(t)$ 间的动态控制关系,同时兼顾风电功率隐特征自身的时序惯性,其核心预测公式如下:

$$\begin{aligned} z(t_1) &= z(t_0) + \int_{t_0}^{t_1} f_{\text{HDE}}(z(t), X(t); \theta) dH(t) = \\ &= z(t_0) + \int_{t_0}^{t_1} f_{\text{HDE}}(z(t), X(t); \theta) \frac{dH(t)}{dt} dt = \\ &= z(t_0) + \int_{t_0}^{t_1} (h_x(t), h(t)) \begin{bmatrix} dX(t) \\ dt \\ 1 \end{bmatrix} dt \end{aligned} \quad (5)$$

式中: $f_{\text{HDE}}(z(t), X(t); \theta)$ 代表以隐特征 $z(t)$ 和风速 $X(t)$ 为输入的混合微分函数,由含参数 θ 的神经网络构建,包括对控制风速的微分项 $h_x(t)$ 和对时间的微分项 $h(t)$; $H(t)$ 为微分向量 $(\frac{dX(t)}{dt}, 1)^T$ 。




图3 NPHDE模型总体框架
Fig. 3 Overall framework diagram of NPHDE model

2.2.2 混合微分函数

f_{HDE} 函数通过学习风电功率隐特征 $\mathbf{z}(t)$ 对控制变量 $\mathbf{H}(t)$ 的微分项, 模拟风功率在风速时序轨迹影响下的控制演化规律。由于已有知识无法直接推导 f_{HDE} 函数的显式表达式, 需要借助参数化的神经网络学习, 选择适合的神经网络结构十分重要。本文设计的 f_{HDE} 神经网络由控制网络和门控网络两部分组成。前者基于 NCDE 模型的控制演化策略采用两层非线性映射网络计算 $\mathbf{h}_x(t)$, 模拟风功率在风速时序轨迹影响下的控制演化规律; 后者则基于 NODE 模型的时间演化机制通过门控网络计算 $\mathbf{h}(t)$, 挖掘风电功率自身的时间惯性规律。

在控制网络部分, 输入为风速轨迹 $X(t)$ 。考虑到风电功率一般与风速的三次方成正比^[20], 对风速的一阶微分为关于风速的二次多项式, 因此用不高于二次的风速乘方项拼接为泛风速轨迹 $\tilde{X}(t) = X(t) \oplus X^2(t)$, 经过两层全连接网络计算风电功率受风速控制的微分项 $\mathbf{h}_x(t)$:

$$\mathbf{h}_x(t) = \tanh(\mathbf{W}_{h_2} \times \text{relu}(\mathbf{W}_{h_1} \tilde{X}(t) + \mathbf{b}_{h_1}) + \mathbf{b}_{h_2}) \quad (6)$$

式中: $\mathbf{W}_*$ 、 $\mathbf{b}_*$ 分别为不同隐含层的权重和偏置, 下同; $\text{relu}(\cdot)$ 、 $\tanh(\cdot)$ 分别代表线性整流和双曲正切激活函数。

在门控网络部分, 输入为风速轨迹 $X(t)$ 和隐特征轨迹 $\mathbf{z}(t)$, 即 $\mathbf{I}(t) = \mathbf{z}(t) \oplus X(t)$ 。受 LSTM 和 GRU 的门控机制启发, 门控网络提取风电功率自身时间惯性信息 $\mathbf{h}(t)$ 的过程如下:

$$\begin{cases} \mathbf{p}(t) = \sigma(\mathbf{W}_p \mathbf{I}(t) + \mathbf{b}_p) \\ \tilde{\mathbf{z}}(t) = \tanh(\mathbf{W}_{z_2}(\text{relu}(\mathbf{W}_{z_1} \mathbf{I}(t) + \mathbf{b}_{z_1})) + \mathbf{b}_{z_2}) \\ \mathbf{h}(t) = \mathbf{p}(t)(\tilde{\mathbf{z}}(t) - \mathbf{z}(t)) \end{cases} \quad (7)$$

与传统 GRU 在离散时间步上进行隐特征更新的方式不同, 式(7)的门控网络基于连续时间框架对隐特征进行动态调整, 提升信息提取的精细度和时序建模的连续性。其中 $\mathbf{p}(t)$ 为更新门, 通过 sigmoid 激活函数将输入映射到 $[0,1]$ 区间; $\tilde{\mathbf{z}}(t)$ 为候选隐特征, 通过与前一时刻隐特征的差分及门控更新, 模拟隐状态的连续时间演化过程。

2.2.3 数值积分求解

NHDE 模型的公式(5)从初始值 $\mathbf{z}(t_0)$ 出发, 依据风电功率的控制演化信息 $\mathbf{h}_x(t)$ 和时间惯性信息 $\mathbf{h}(t)$ 分别对风速时序轨迹 $X(t)$ 和时间 t 进行积分。在处理以时间 t 为控制变量的 NODE 模型时, 积分运算通常依赖于数值积分方法, 例如欧拉(Euler)、龙格-库塔(Runge-Kutta)、多尔曼-普林斯(Dormand-Prince)等经典技术。由于经由三次样条插值形成的时序轨迹 $X(t)$ 满足二阶连续可微的条件, NCDE 积

分项也可以通过数值离散化积分获得近似解。因此, 针对 NHDE 模型中的积分公式, 本文采用固定步长的欧拉法, 将连续的积分过程近似为一系列离散的迭代加法运算:

$$\mathbf{z}(t + \Delta t) = \mathbf{z}(t) + \Delta t \cdot (f_{\text{HDE}}(\mathbf{z}(t), X(t); \theta) \frac{d\mathbf{H}(t)}{dt}) \quad (8)$$

经由欧拉法的积分求解, 遍历预测时段内的各目标时点, 得到预测时段内隐状态 $\mathbf{z}(t)$ 。最后, 将 $\mathbf{z}(t)$ 与风速 $X(t)$ 经过如下两层全连接网络, 得到风功率初始预测结果:

$$\mathbf{o}(t) = \tanh(\mathbf{W}_{o_2}(\text{relu}(\mathbf{W}_{o_1}(\mathbf{z}(t) \oplus X(t)) + \mathbf{b}_{o_1})) + \mathbf{b}_{o_2}) \quad (9)$$

2.3 分段控制策略

在实际工程中, 风速对风机输出功率的控制模式通常可用如下分段函数关系来描述^[20]:

$$P_t = \begin{cases} 0, & v_t < v_{\text{in}} \\ g(v_t), & v_{\text{in}} < v_t < v_N \\ P_N, & v_N < v_t < v_{\text{out}} \\ 0, & v_t > v_{\text{out}} \end{cases} \quad (10)$$

式中: v_t 和 P 分别代表 t 时刻的输入风速和输出风电功率; P_N 是额定输出功率; $g(v_t)$ 是以输入风速为自变量的输出功率函数, 一般表示为风速的一次或三次线性函数; v_{in} 、 v_N 、 v_{out} 分别为风机的切入、额定和切出风速。

为提高风功率预测结果的合理性, 预测模型中风速对风功率的控制模式分类也应遵循式(10)所示的三段四区间形式。即 2.2 节所述 NHDE 模型仅在 $v_{\text{in}} < v_t < v_N$ 的风速区间内模拟风电功率随风速的动态变化, 而在 $v_t < v_{\text{in}}$ 或 $v_t > v_{\text{out}}$ 的情况下风电出力为 0, 在 $v_N < v_t < v_{\text{out}}$ 的情况下固定为额定输出功率 P_N 。然而, 考虑到风速的波动性和气象环境的固有不确定性, 风速控制模式类型和区间分界点具有模糊性, 不能单纯依赖于经验判断或传统的风能转换曲线来固定划分控制区间。因此, 本文利用 softmax 线性层动态学习在各时刻风速 $X(t)$ 落入 4 种控制模式区间的隶属度权重, 以灵活适应风速的变化。分段控制策略流程如图 4 所示。




图 4 分段控制策略流程

Fig. 4 Flowchart of the piecewise control strategy

图中 $w_{i,t}$ 为 t 时刻风速落入 4 种控制区间的隶属度权重向量, 计算公式见式(11)。不同时刻的 w_t 随着风速 x_t 值的变化动态变化, 但同一时刻 w_t 中的 4 个权重值满足位于 $[0,1]$ 区间内、且总权重和为 1 的约束。

$$\begin{cases} w_t = \text{softmax}(W_{w2}(\text{relu}(W_{w1}x_t + b_{w1})) + b_{w2}) \\ w_t = \{w_{i,t}, i=1,2,3,4\} \\ \text{s.t. } \sum_{i=1}^4 w_{i,t} = 1 \end{cases} \quad (11)$$

预测模型先通过 NHDE 模型获得 t_i 处的初步预测结果 $o(t_i)$; 然后将该时点处的输入风速 x_i 送入多层感知器, 通过多层感知器的权重分配网络生成对应 4 个风速控制区间的隶属度权重向量 $w_t = \{w_{i,t}, i=1,2,3,4\}$; 将 4 个控制区间预测功率的加权计算结果经过全连接层得到最终风电功率预测结果 $\hat{y}(t_i)$, 如式(12)所示:

$$\hat{y}_t = W_y(w_{1,t} \cdot 0 + w_{2,t} \cdot o_t + w_{3,t} \cdot 1 + w_{4,t} \cdot 0) + b_y = W_y(w_{2,t} \cdot o_t + w_{3,t}) + b_y \quad (12)$$

式中: 0 和 1 分别为零和额定功率输出的归一化值。

在模型训练过程中, 通过最小化公式(13)的损失函数, 优化多层感知器的参数, 获得输入风速值与控制区间隶属权重之间的最佳映射关系:

$$\text{Loss}(y_t, \hat{y}_t) = \frac{1}{n} \sum_t (y_t - \hat{y}_t)^2 + \lambda \sum_j \|w_j\|_2 \quad (13)$$

式中: n 为训练样本数据点个数; $\hat{y}_t$ 和 y_t 分别为风电功率在 t 时刻的预测结果和实际值;

$\frac{1}{n} \sum_t (y_t - \hat{y}_t)^2$ 为均方误差(mean squared error, MSE); $\|w_j\|_2$ 是每个模型参数的 L2 范数; λ 为正则化系数。

3 算例分析

3.1 算例简介

选取中国北方某风电场(风电场 1)2019 年 1 月至 2020 年 12 月(分辨率 15min)、中部地区某风电场(风电场 2)2023 年 1 月至 2024 年 12 月(分辨率 5min)的风速和功率数据, 进行未来 24 小时的短期风电功率预测。数据以 7:1.5:1.5 划分为训练集、验证集和测试集。通过计算风电场 1 的功率与不同高度预测风速之间的皮尔逊相关系数(图 5), 选择与该风电场相关度最高的 70m 处风速为输入特征。

考虑到实验数据存在不规则性, 传统基于固定时间步长的预测模型难以直接适用, 因此对比模型选择 GRU-dt[10]、GRU-D[14]、NCDE[10]和 ODE-RNN^[16]。其中, GRU-dt 模型在 GRU 基础上增加了




图 5 风电功率与不同高度风速的相关性热力图
Fig. 5 Heatmap of the correlation between wind power and wind speed at different altitudes

输入特征时间序列的时间差额作为额外输入。GRU-D 模型则在增加了可学习的指数衰减函数。为了测试各预测模型对不规则时间间隔输入时间序列的适应性, 对输入数据集设置缺失率分别为 10%、20%、30% 的随机缺失。同时, 为降低缺失值随机分布对预测评价客观性的影响, 各模型在每种缺失率下分别进行 5 次随机缺失实验, 取预测误差的平均值度量该缺失率下模型的预测精度, 并统计其波动量(最大、最小值之差)和 NPHDE 模型相对于对比模型的改善率(Improvement Rate, Imp)。运行环境为 Python3.8, 2.20GHz Intel®Core(TM)i7-8750H/16GB 内存。各模型的超参数统一设置 batch 为 32, epoch 为 100, 学习率为 0.001, 隐藏层神经单元数为 100, 正则化系数为 0.03。模型中的积分运算采用步长取 0.5(分辨率间隔归一化至 0-1 区间后的取值)的欧拉法, 初始值取前一日最后时刻的真实风电功率值。

选择平均绝对百分比误差(mean absolute percentage error, MAPE)和均方根误差(root mean square error, RMSE)作为预测精度的评价标准:

$$E_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{y}_t - y_t|}{P_N} \times 100\% \quad (14)$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_t - y_t)^2} \quad (15)$$

3.2 各模型预测结果的对比

表 1 列出了两座风电场测试集输入风速缺失率分别为 0%(规则序列)、10%、20%、30% 条件下各模型的风电功率预测误差指标值。图 6 给出了风电场 1 在风速缺失率为 10% 和 30% 时, 各模型在某测试日的风电功率预测曲线, 为客观对比同一时段内缺失点增加对预测结果的影响, 当缺失率增加时, 保留原缺失点的同时递增缺失点数量。风速缺失率为 0% 和 20% 时各模型在同一测试日的风电功率预




图 6 两种输入风速缺失率下各模型预测功率曲线对比
Fig. 6 Comparison of predicted power curves by various models under two different wind speed input missing rates

表 1 不同风速缺失率下的各模型预测误差对比
Table 1 Model prediction error comparison at different wind speed missing rates

MAPE/%																					
风电场 1												风电场 2									
预测模型	输入数据的缺失情况																				
	0%			10%			20%			30%			0%		10%		20%		30%		
	均值/%	I_{mp}		均值/%	I_{mp}	波动/%	均值/%	I_{mp}	波动/%	均值/%	I_{mp}	波动/%	均值/%	I_{mp}	波动/%	均值/%	I_{mp}	波动/%	均值/%	I_{mp}	波动/%
GRU-dt	6.14	0.52		6.33	0.59	0.16	6.58	0.64	0.14	6.82	0.76	0.17	12.1	12.13	0.16	12.17	0.14	12.2	0.14		
GRU-D	6.26	0.64		6.48	0.74	0.12	6.67	0.73	0.09	6.87	0.81	0.14	12.13	12.18	0.07	12.22	0.08	12.24	0.06		
ODE-RNN	6.67	1.05		6.93	1.19	0.53	6.95	1.01	0.32	6.88	0.82	0.23	23.93	21.04	1.56	20.28	1.66	22.55	3.97		
NCDE	6.78	1.16		7.25	1.51	0.67	7.15	1.21	0.51	6.92	0.86	0.17	11.75	10.46	0.35	10.8	0.35	10.89	0.18		
NPHDE	5.62	—		5.74	—	0.2	5.94	—	0.17	6.06	—	0.66	8.88	8.97	0.21	8.99	0.07	9.97	0.69		
R_{MSE}/MW																					
风电场 1												风电场 2									
预测模型	输入数据的缺失情况																				
	0%			10%			20%			30%			0%		10%		20%		30%		
	均值/MW	$I_{mp}/\%$		均值/MW	$I_{mp}/\%$	波动/MW	均值/MW	$I_{mp}/\%$	波动/MW	均值/MW	$I_{mp}/\%$	波动/MW	均值/MW	$I_{mp}/\%$	波动/MW	均值/MW	$I_{mp}/\%$	波动/MW	均值/MW	$I_{mp}/\%$	波动/MW
GRU-dt	9.2	3.88		9.47	8.66	0.36	9.81	10.09	0.24	10.12	10.57	0.38	16.05	16.08	0.12	16.18	0.09	16.22	0.11		
GRU-D	9.2	5.76		9.5	8.95	0.48	9.82	10.18	0.24	10.28	11.96	0.42	16.72	16.34	0.08	16.39	0.14	16.45	0.06		
ODE-RNN	9.48	8.54		9.82	11.91	0.71	9.78	9.92	0.3	9.91	8.68	0.64	28.2	25.21	2.93	24.18	1.71	25.59	2.68		
NCDE	9.93	12.69		10.62	18.55	0.44	10.23	13.78	0.64	10.19	11.19	0.85	16.11	14.91	0.71	14.74	0.44	14.91	0.22		
NPHDE	8.67	—		8.65	—	0.17	8.82	—	0.08	9.05	—	0.25	12.34	12.51	0.44	12.44	0.08	13.87	0.52		

注: 波动为 5 次随机缺失实验结果中最大值与最小值之间的差额; I_{mn} 为 NPHDE 模型相较于对比模型在评价指标上的改进百分点。

个百分点, RMSE 误差下降 8.54%~11.91%。NCDE 模型的误差指标在风电场 1 的中等缺失率(10%)下明显增大。相比之下, 融合了 NCDE 和 NODE 优势的 NPHDE 模型在各缺失率场景下展现出更高的鲁棒性, 其在风电场 1 中的 MAPE 和 RMSE 误差比 NCDE 模型分别下降了 0.86%~1.51%和 11.19%~18.55%, 体现出 NPHDE 模型在捕捉时序演化规律和控制关系方面的优势。结合图 6 进一步观察到, 无论在 10%还是 30%的风速缺失率条件下, 相较于对比模型, NPHDE 模型的预测结果在大多数缺失点处与真实值更接近。

为观察 NPHDE 模型的训练过程, 图 7 展示了 NPHDE 模型在风电场 1 不同缺失率下训练集损失随训练轮次的变化情况。从图 7 可以看出, 模型在 0%、10%、20%和 30%缺失率下均能快速收敛, 且在较低误差水平下趋于稳定, 表明模型对缺失率的敏感性较低。训练过程中 MSE 波动较小, 尤其是在迭代后期, MSE 几乎不变, 验证了模型的稳定性。此外, 尽管随着缺失率的增加, MSE 略有上升, 但差异较小, 说明 NPHDE 模型能有效适应不同程度的数据缺失场景。




图 7 训练集损失与训练轮次关系图

Fig. 7 Relationship between Training Loss and Epochs

3.3 适应性分析

为验证 NPHDE 模型的适应能力, 本节从不同风电场和不同训练集规模两方面开展对比研究。两组实验除了数据来源或训练集规模不同外, 其余参数配置与 3.2 节一致。另外, 考虑到表 1 中各模型在不同缺失率下和不同误差指标类型的性能变化相似, 以 20%缺失率场景为代表, 两组适应性实验的 MAPE 误差对比结果见表 2。

从表 2 可以看出, 在针对不同风电场的对比实验 1 中, 各模型对风电场 2 出力的预测精度不如风电场 1, 其 MAPE 误差比风电场 1 增加了 3.05%~

表 2 20%缺失率下适应性实验的 MAPE 预测误差对比
Table 2 Comparison of MAPE prediction errors in adaptive experiments under 20% missing data rate %

模型	实验 1 (风电场 2VS 风电场 1)		实验 2 (1 年训练样本 VS 2 年训练样本)	
	均值	上升度	均值	上升度
GRU-dt	12.17	5.59	6.71	0.57
GRU-D	12.22	5.55	6.58	0.32
ODE-RNN	20.28	13.33	6.92	0.25
NCDE	10.80	3.65	6.64	0.14
NPHDE	8.99	3.05	5.83	0.21

注: 实验 1 中上升度为风电场 2 相对于风电场 1 的 MAPE 误差增加量; 实验 2 中上升度为风电场 1 将训练数据集由 2 年减少为 1 年后 MAPE 误差的增加量。

13.33%。但本文所提 NPHDE 模型的 MAPE 误差增加幅度相对较小, 约为 3.05%; 同时, 对于同为基于 NDE 框架下的 NCDE 模型, 风电场 2 的 MAPE 增幅也小于 4%。相比之下, ODE-RNN 和 RNN 类模型增幅均超过 5%。由此可见, 基于 NDE 框架的预测模型对不同风电场的适应性普遍强于基于 RNN 框架的预测模型。

在针对不同训练样本集规模的实验 2 中, 表 2 结果表明, 基于 NDE 框架的 NPHDE 与 NCDE 模型对训练样本量变化的适应性更强, 即使训练样本规模减半, 它们的 MAPE 误差仅增加 0.14%~0.21%。相比之下, RNN 类模型的 MAPE 误差增加 0.25%~0.57%。表明引入积分推演机制有利于提高风电预测模型在面对训练样本规模变化时的稳定性。

3.4 消融实验

本节采用风电场 1 的数据, 对所提 NPHDE 模型设计消融实验以验证其在时间演化机制、控制演化机制和分段控制策略方面的有效性。4 种基于 NPHDE 模型的消融模型如下:

1) NPHDE-D: 固定风速控制区间及其权重:

$$w_t = \begin{cases} [1, 0, 0, 0], & v_t < v_{in} \\ [0, 1, 0, 0], & v_{in} < v_t < v_N \\ [0, 0, 1, 0], & v_N < v_t < v_{out} \\ [0, 0, 0, 1], & v_t > v_{out} \end{cases} \quad (16)$$

2) NPHDE-P: 去除风速对风电功率的分段控制策略;

3) NPHDE-O: 将 NHDE 替换为 NCDE, 忽略风功率自身的时序惯性;

4) NPHDE-C: 将 NHDE 替换为 NODE, 去除风速对风功率的控制特性。

消融实验的误差统计如图 8 所示。从图中可以看出, 相较于 NPHDE 模型, 消融模型的预测误差有不同程度上升。具体而言, 采用固定风速控制区间后, NPHDE-D 模型的 MAPE 和 RMSE 误差分别

增加了 0.11% 和 0.19MW; 去除风速对风电功率的分段控制策略后, NPHDE-P 模型的 MAPE 和 RMSE 分别增加了 0.39% 和 0.22MW。表明忽略或固定风速对功率的分段控制模式, 都将难以准确模拟风速对功率的动态控制机制, 导致预测精度下降。

为直观观察分段控制权重的变化, 图 9 将实验结果可视化。图 9(a) 对比了 NPHDE、NPHDE-D 和 NPHDE-P 模型在某测试日的预测曲线, 图 9(b) 和 9(c) 通过热力图对比同一预测日内 NPHDE 和 NPHDE-D 模型的风速控制区间权重分布, 其中热力图的颜色越深, 代表风速落入纵坐标对应控制区间的权重越大。从图 9(a) 可以观察到, 在第 1~20 时点内的部分风速低于实际切入风速, 实际输出功率为 0, 应归属于分区 1。采用风速分段控制策略的 NPHDE 和 NPHDE-D 模型(分别为红线和紫线)相比于未采用风速分段控制策略的 NPHDE-P 模型(蓝线), 其预测结果更接近实际输出功率值。对应时点在 NPHDE-D 模型中区间 1 的权重为 1(见图 9(b)), 在 NPHDE 模型中区间 1 的权重虽不等于 1, 但也出现了颜色变深的隶属度(见图 9(c))。当第 30~80 时点内风速变化导致功率剧烈波动时, 采用风速分段控制策略的 NPHDE 和 NPHDE-D 模型能迅速调整预测模式以匹配实际功率的变化, 但两者的控制区间权重呈现出明显差异。以第 30~50 时点区间为例, 对应的风机实际输出功率因风速动态变化在额定功率(100MW)附近波动, 固定控制区间的 NPHDE-D 模型依据图 9(b) 中的 0/1 分区权重输出功率, 导致大多数时点的预测值落入额定功率, 无法精准贴合实际功率曲线。而图 9(c) 中 NPHDE 模型根据风速的动态变化自适应确定其落入 4 种控制区间的隶属度权重, 并不要求权重为 0 或 1, 可以是位于 [0,1] 区间的任意连续值, 使得预测曲线在整体趋势上与实际功率曲线的波动更相似。





图 8 消融实验误差统计图

Fig. 8 Statistical figure of ablation experiment error



(a) 消融模型预测曲线对比图




图 9 分段控制策略的有效性验证

Fig. 9 Validation of the effectiveness of the segmented control strategy

从图 8 还可以观察到, 去除风速对风功率的控制特性后, NPHDE-C 模型的 MAPE 和 RMSE 误差分别增加了 1.03% 和 1.11MW; 忽略风电功率自身的时序惯性后, NPHDE-O 模型的 MAPE 和 RMSE 误差分别增加了 0.85% 和 0.9MW, 这说明风速控制演化特性和时序惯性在揭示风电功率内部动态规律方面具有重要作用。结合分段控制策略的实验结论可知, 风速控制演化特性对模型预测精度提升的贡献最大, 其次是时序惯性, 再次是分段控制策略。综合来看, 这 3 种机制在提升风电功率预测精度方面均发挥了不可或缺的作用, 三者结合可更全面模拟风电功率演化规律, 提高模型的预测性能。

3.5 超参数对预测结果的影响

本节采用风电场 1 的数据, 分析 NPHDE 模型核心超参数隐藏层神经元数量 m 、学习率 l 、欧拉步长 Δt 的取值对预测性能的影响。当考察某超参数时, 其他超参数固定在最优值。

3.5.1 隐藏层神经元个数 m

图 10 显示了神经元个数 m 从 16 增加到 128 时, NPHDE 模型 MAPE 和 RMSE 误差的变化情况。随着 m 的增加, RMSE 和 MAPE 总体呈现出相似变化趋势, 其中 MAPE 在 5.63~6.90% 内波动, 最大偏差为 1.27%。当 m 较小时, 隐特征信息储存不足, 预测误差较大; 随着 m 增加, 隐特征容量增大, 预

测误差减小;当 m 增加到一定阈值后,数量庞大的模型参数可能因训练样本有限而无法训练充分,导致误差增大。本算例最优 m 值为100。

3.5.2 学习率 l

图11为模型学习率 l 在 $[0.0001, 0.01]$ 区间内变化时NPHDE模型的预测误差统计图。理论上模型使用较大的学习率可能会跳过最优解;而较小学习率下的模型可能无法充分拟合训练数据。从图11可以看出,随着学习率 l 从0.01减小到0.0005,模型的MAPE误差只在5.63~5.67%的小范围内波动,最大偏差仅为0.04%,RMSE的最大偏差也仅为0.3MW。这说明在这一范围内,学习率 l 的变化对模型收敛性能和预测误差影响有限。然而,随着学习率 l 进一步减小到0.0001,由于更新步幅过小,训练过程易陷入局部最优解或早停,导致模型误差显著增加。本算例选择的最优 l 值为0.001。




图10 不同隐藏层神经元个数对应的误差变化

Fig. 10 Errors corresponding to the number of neurons in different hidden layers




图11 不同学习率对应的误差变化

Fig. 11 Errors corresponding to different learning rates

3.5.3 欧拉步长 Δt

图12显示了NPHDE模型的预测误差和单个样本训练耗时随 Δt 的变化曲线,其中横坐标 $\Delta t=1$ 对




图12 不同欧拉积分步长对应的误差变化

Fig. 12 Error changes corresponding to different Euler integration steps

应原始输入时间序列的时间步长(风电场1算例中为15min)。观察曲线可以发现,随着隐特征积分中 Δt 从0.1增加到1,模型的MAPE预测误差呈现出先降后升的趋势,在5.48~6.14%范围内波动,最大偏差量为0.66%,当 $\Delta t=0.3$ 时模型的MAPE到达最低值5.48%,而样本训练耗时会随积分步长减小而迅速增大。当适当减小步长时,积分过程更精确,但过小的步长(如 $\Delta t=0.1$ 时)会使训练过程的计算量和计算时间显著增加,进而导致计算误差积累,降低整体预测精度。综合考虑预测精度与训练耗时,选择本算例的最优积分步长为0.5。

4 结论

为增强风电功率时序预测中处理不规则采样数据的能力,充分利用风速-功率的分段控制特性,提高预测结果的准确性与可信度,本文提出一种基于分段控制混合微分神经网络(NPHDE)的短期风电功率预测方法。通过实际算例与现有预测模型的对比分析,得出以下结论:

1) 引入基于NDE框架的动态推演机制,显著提升了短期风电功率预测模型对不同风电场、不同样本规模和不同程度缺失率输入的适应性。

2) 控制演化策略和时间演化机制是NPHDE模型预测精度提升的关键,而分段控制策略可提高预测模型适应风速变化的灵活性。引入控制演化策略可降低MAPE误差1.03%,引入时间演化机制可降低MAPE误差0.85%,引入分段控制策略可降低MAPE误差0.39%。

3) 超参数在平衡预测精度与计算效率方面具有重要作用。隐藏层神经元数目 m 是影响预测精度的重要参数;学习率 l 在一定范围内变化时对预测性能影响不大;适当减小欧拉步长 Δt 可提高预测精

度, 但训练耗时会大幅增加。

本文初步探索了基于 NDE 框架的神经混合微分方程在短期风电功率预测中的应用潜力, 未来研究可进一步优化模型积分运算的数值求解技术, 以提高训练效率。该方法具有较强的通用性, 可推广至同样具有时序性特点的太阳能发电和负荷预测领域, 为新型电力系统更多应用场景提供精准、可靠的动态预测工具。

附录见本刊网络版 (<http://www.dwjs.com.cn/CN/1000-3673/current.shtml>)。

参考文献

- [1] WANG Jianzhou, ZHANG Lifang, WANG Chen, et al. A regional pretraining-classification-selection forecasting system for wind power point forecasting and interval forecasting[J]. *Applied Soft Computing*, 2021, 113: 107941.
- [2] 薛禹胜, 郁琛, 赵俊华, 等. 关于短期及超短期风电功率预测的评述[J]. *电力系统自动化*, 2015, 39(6): 141-151.
XUE Yusheng, YU Chen, ZHAO Junhua, et al. A review on short-term and ultra-short-term wind power prediction[J]. *Automation of Electric Power Systems*, 2015, 39(6): 141-151(in Chinese).
- [3] 李丹, 方泽仁, 缪书唯, 等. 考虑训练样本分布不均衡的超短期风电功率概率预测[J]. *电网技术*, 2024, 48(3): 1133-1145.
LI Dan, FANG Zeren, MIAO Shuwei, et al. Probability prediction of ultra-short-term wind power considering unbalanced distribution of training samples[J]. *Power System Technology*, 2024, 48(3): 1133-1145(in Chinese).
- [4] 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): 2897-2904.
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): 2897-2904(in Chinese).
- [5] 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(in Chinese).
- [6] 胡帅, 向月, 沈晓东, 等. 计及气象因素和风速空间相关性的风电功率预测模型[J]. *电力系统自动化*, 2021, 45(7): 28-36.
HU Shuai, XIANG Yue, SHEN Xiaodong, et al. Wind power prediction model considering meteorological factor and spatial correlation of wind speed[J]. *Automation of Electric Power Systems*, 2021, 45(7): 28-36(in Chinese).
- [7] 陈峰, 余轶, 徐敬友, 等. 基于 Bayes-LSTM 网络的风电出力预测方法[J]. *电力系统保护与控制*, 2023, 51(6): 170-178.
CHEN Feng, YU Yi, XU Jingyou, et al. Prediction method of wind power output based on a Bayes-LSTM network[J]. *Power System Protection and Control*, 2023, 51(6): 170-178(in Chinese).
- [8] 刘新宇, 蒲欣雨, 李继方, 等. 基于贝叶斯优化的 VMD-GRU 短期风电功率预测[J]. *电力系统保护与控制*, 2023, 51(21): 158-165.
LIU Xinyu, PU Xinyu, LI Jifang, et al. Short-term wind power prediction of a VMD-GRU based on Bayesian optimization[J]. *Power System Protection and Control*, 2023, 51(21): 158-165(in Chinese).
- [9] BLEISTEIN L, GUILLOUX A. On the generalization and approximation capacities of neural controlled differential equations [M]. *arXiv preprint arXiv: 2305.16791*, 2023.
- [10] TAN Qingxiong, YE Mang, YANG Baoyao, et al. DATA-GRU: dual-attention time-aware gated recurrent unit for irregular multivariate time series[C]//*Proceedings of the Thirty-Fourth AAAI Conference on Artificial Intelligence*. New York: AAAI Press, 2020: 930-937.
- [11] WELLS B J, NOWACKI A S, CHAGIN K, et al. Strategies for handling missing data in electronic health record derived data[J]. *eGEMS*, 2013, 1(3): 7.
- [12] 李丹, 唐建, 缪书唯, 等. 考虑时序特征缺失值动态插补的超短期风电功率预测[J/OL]. *中国电机工程学报*, 2024: 1-15[2024-07-25]. <http://kns.cnki.net/kcms/detail/11.2107.tm.20240425.1905.005.html>.
LI Dan, TANG Jian, MIAO Shuwei, et al. Ultra-short-term wind power prediction considering dynamic interpolation of missing values of time series features[J/OL]. *Proceedings of the CSEE*, 2024: 1-15[2024-07-25]. [http://kns.cnki.net/kcms/detail/11.2107.tm.20240425.1905.005.html\(in Chinese\)](http://kns.cnki.net/kcms/detail/11.2107.tm.20240425.1905.005.html(in Chinese)).
- [13] KIDGER P, MORRILL J, FOSTER J, et al. Neural controlled differential equations for irregular time series[C]//*Proceedings of the 34th International Conference on Neural Information Processing Systems*. Vancouver: Curran Associates Inc., 2020.
- [14] CHE Zhengping, PURUSHOTHAM S, CHO K, et al. Recurrent neural networks for multivariate time series with missing values[J]. *Scientific Reports*, 2018, 8(1): 6085.
- [15] CHEN R T Q, RUBANOVA Y, BETTENCOURT J, et al. Neural ordinary differential equations[C]//*Proceedings of the 32nd International Conference on Neural Information Processing Systems*. Montréal, Canada: Curran Associates Inc., 2018: 6572-6583.
- [16] RUBANOVA Y, CHEN R T Q, DUVENAUD D. Latent ODEs for irregularly-sampled time series[C]//*Proceedings of the 33rd International Conference on Neural Information Processing Systems*. Vancouver: Curran Associates Inc., 2019: 5320-5330.
- [17] MORRILL J, KIDGER P, YANG Lingyi, et al. Neural controlled differential equations for online prediction tasks[M]. *arXiv preprint arXiv: 2106.11028*, 2021.
- [18] JHIN S Y, SHIN H, HONG S, et al. Attentive neural controlled differential equations for time-series classification and forecasting [C]//*2021 IEEE International Conference on Data Mining (ICDM)*. Auckland, New Zealand: IEEE, 2021: 250-259.
- [19] CHOI J, CHOI H, HWANG J, et al. Graph neural controlled differential equations for traffic forecasting[C]//*Proceedings of the Thirty-Sixth AAAI Conference on Artificial Intelligence*. Held Virtually: AAAI Press, 2022: 6367-6374.
- [20] 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.
- [21] 臧海祥, 赵勇凯, 张越, 等. 基于低风速功率修正和损失函数改进的超短期风电功率预测[J]. *电力系统自动化*, 2024, 48(7): 248-257.
ZANG Haixiang, ZHAO Yongkai, ZHANG Yue, et al. Ultra-short-term wind power prediction based on power correction under low wind speed and improved loss function[J]. *Automation of Electric Power Systems*, 2024, 48(7): 248-257(in Chinese).
- [22] CICCONE M, GALLIERI M, MASCI J, et al. NAIS-NET: stable deep networks from non-autonomous differential equations[C]//*Proceedings of the 32nd International Conference on Neural Information Processing Systems*. Montréal: Curran Associates Inc., 2018.



李丹

在线出版日期: 2025-08-14。

收稿日期: 2025-03-24。

作者简介:

李丹(1980), 女, 博士, 副教授, 研究方向为新能源发电和负荷预测及电力系统优化调度, E-mail: lucy2140@163.com;

黄烽云(2000), 通信作者, 男, 硕士研究生, 研究方向为电力系统运行与控制, E-mail: 13477364932@163.com。

(责任编辑 赵梓含)




图 A1 规则输入风速下各模型的风电功率预测曲线对比

Fig. A1 Comparison of Wind Power Prediction Curves of Various Models under Rule-Based Input Wind Speed




图 A2 输入风速在 20%缺失率条件下各模型的风电功率预测曲线对比

Fig. A2 Comparison of Wind Power Prediction Curves of Various Models under 20% Missing Rate Condition for Input Wind Speed




图 A3 隐特征更新过程对比图

Fig. A3 Comparison of the hidden feature update process