基于秒级阵风预测的风电机组转速备用模式动态切换策略

胡张勤[1]，王镜毓[2]，黄思哲[1]，黄轶翔[1]，石东源[1]，姚伟[1]
（1. 华中科技大学电气与电子工程学院，武汉市 430074；2. 强电磁技术全国重点实验室（华中科技大学），武汉市 430074）

摘　要：【目的】高比例风电并网导致系统等效惯量下降，频率稳定问题突出，风电的大规模接入使该问题更为复杂。阵风波动剧烈、随机性强，现有确定性风速预测方法难以捕捉其高频瞬变特征，导致风机转速备用模式切换滞后与误动，制约机组的暂态频率支撑能力。为提升风机的调频性能，提出了一种融合概率预测与不确定性感知的自适应切换策略。【方法】首先，构建基于去噪扩散概率模型与Transformer融合架构的秒级阵风概率预测模型，引入风机多维度状态参数作为辅助条件，通过蒙特卡罗采样生成概率预测轨迹。其次，设计基于动态置信走廊的自适应切换策略，构建动作阈值与返回阈值作为模式切换的依据；对置信走廊穿越阈值区域的模糊决策场景，采用概率评估方法计算风速超越阈值的概率，依据概率阈值来实现超速减载与低速减载模式的前瞻性主动切换。【结果】基于某海上风电场数据采集与监视控制系统（supervisory control and data acquisition，SCADA）数据的仿真表明：所提秒级阵风概率预测模型在预测准确性上比长短期记忆（long short-term memory，LSTM）网络、时间卷积网络（temporal convolutional network，TCN）模型更优；所提预测模型在自适应切换策略中将平均切换点的时间提前 3.6 s，预测可靠性与响应精度均有较大提升，显著提升了阵风场景下的风机备用功率裕度。【结论】所提模型与方法通过高置信概率预测与不确定性感知决策，实现了风电机组转速备用模式从“被动响应”到“主动预判”的转换，有效抑制了因阵风预测不准导致模式频繁切换所引发的控制误动，在保障机组安全运行的同时最大化暂态调频能力，为高比例风电电力系统的频率稳定控制提供了可行方案。

关键词：风电机组；阵风预测；去噪扩散概率模型；自适应切换；不确定性感知
中图分类号：TM614　　**文献标志码**：A　　**文章编号**：1000-7229（2026）10-0109-13
DOI：10.12204/j.issn.1000-7229.2026.10.009

Second-level Gust Forecast Based Dynamic Switching Strategy for Wind Turbine Speed-Reserve Mode

HU Zhangqin[1], WANG Jingyu[2], HUANG Sizhe[1], HUANG Yixiang[1], SHI Dongyuan[1], YAO Wei[1]
（1. School of Electrical and Electronic Engineering, Huazhong University of Science and Technology, Wuhan 430074, China; 2. National State Key Laboratory of Advanced Electromagnetic Technology, Huazhong University of Science and Technology, Wuhan 430074, China）

ABSTRACT: [**Objective**] High wind penetration reduces system inertia and threatens frequency stability, and the large-scale integration of wind power makes this problem more complex. Gusts are highly fluctuating and random; existing deterministic wind speed prediction methods cannot capture their high-frequency transient features, causing lag and misoperation in rotor speed reserve mode switching and limiting the turbine's transient frequency support capability. To improve frequency regulation, an adaptive switching strategy integrating probabilistic prediction and uncertainty awareness was proposed. [**Methods**] A second-level gust probabilistic prediction model was built using a denoising diffusion probabilistic model (DDPM)-Transformer architecture, with multi-dimensional turbine state parameters as auxiliary conditions, and Monte Carlo sampling was used to generate probabilistic prediction trajectories. An adaptive switching strategy based on a dynamic confidence corridor was designed, using action and return thresholds as the basis for mode

基金项目：国家电网有限公司科技项目（52110425001F-021-ZN）

© Editorial Department of Electric Power Construction. OA under CC BY-NC-ND 4.0.

switching. For fuzzy decision scenarios where the confidence corridor crosses the threshold region, the probability of wind speed exceeding the threshold was calculated, and proactive switching between over-speed deloading (OSD) and under-speed deloading (USD) modes was achieved based on the probability threshold. [**Results**] Simulations based on SCADA data from an offshore wind farm show that the proposed second-level gust probabilistic prediction model outperforms long short-term memory (LSTM) and temporal convolutional network (TCN) models in prediction accuracy. In the adaptive switching strategy, the proposed prediction model advances the average switching point by 3.6 s, significantly improves prediction reliability and response accuracy, and significantly enhances the turbine reserve power margin under gust scenarios. [**Conclusions**] Through high-confidence probabilistic prediction and uncertainty-aware decision-making, the proposed model and method achieve a shift from passive response to active anticipation for wind turbine speed reserve modes, suppress control misoperations caused by frequent mode switching due to inaccurate gust prediction, maximize transient frequency regulation capability while ensuring turbine safety, and offer a feasible solution for frequency stability control in power systems with high wind penetration.

This work is supported by State Grid Corporation of China Science and Technology Projects(No. 52110425001F-021-ZN).

KEYWORDS: wind turbine; gust forecasting; denoising diffusion probabilistic model; adaptive switching; uncertainty awareness

0 引 言

在“双碳”目标的引领下,风电等新能源在电力系统中的渗透率持续提高[1-4]。然而,风电机组通过电力电子变流器并网,其转速与电网频率本质解耦,无法类似传统同步发电机一样为系统提供惯量支撑[5-7]。这导致高比例风电并网场景下,电力系统的等效惯量水平显著下降。当电网遭遇大功率扰动时,系统难以依靠足够的转动惯性来有效抑制频率波动,频率失稳风险加剧,对电力系统的安全稳定运行构成严峻挑战[8-12]。深入挖掘并有效利用风电机组自身的调频能力,可以为保障新型电力系统频率安全提供重要支撑。

风电机组的调频过程涵盖惯量响应与一次调频两个阶段,两者作用的时间尺度不同[13-16]。其中,惯量响应作用于秒级暂态过程,其首要目标是快速抑制频率变化率;而一次调频则作用于分钟级过程,其核心任务在于缓解系统的稳态频率偏差[17-20]。

高比例风电并网导致系统等效惯量下降,风电机组参与暂态频率支撑已成为研究热点。现有研究主要围绕减载运行、惯量响应和一次调频控制展开。文献[21]考虑风速差异性,提出了风电场减载功率分配方案,在提升调频能力的同时抑制了频率二次跌落。文献[22]提出了改进的转子转速与桨距角协调控制策略,在全风速范围内预留调频功率裕度,实现快速持续有功支撑并兼顾疲劳载荷抑制。文献[23]通过修改功率跟踪特性曲线,将惯量响应与一次调频支撑统一于功率跟踪特性的调整中。然而,现有暂态频率支撑研究多聚焦于稳态或缓慢变化风速条件下的调频控制策略,对阵风快速波动场景下不同转速备用模式的动态切换问题关注较少,缺乏结合高精度风速预测与不确定性量化的前瞻性控制方法[24-26]。

目前,工程实践中多采用基于深度学习的时序预测方法,如长短期记忆(long short-term memory,LSTM)网络、时间卷积网络(temporal convolutional network,TCN)等方法进行风速预测。然而,此类方法通常旨在输出确定性预测值,其建模过程往往依赖对历史序列整体趋势的拟合,使输出结果易受训练数据中平稳工况的主导而趋向于均一化[27],难以有效捕捉阵风高频、瞬变特征,导致预测结果平滑化,阵风风速预测能力不足,引起模式切换滞后,影响调频效果与机组安全[28]。

为提升风速预测的精度,目前已经提出了多种改进方案,文献[29]提出了一种基于预测误差模态分解的改进LSTM秒级风速预测方法,通过提取误差中的有效信息,实时修正预测风速,提升了未来风速的预测精度。文献[30]提出了一种考虑多特征数据的新型混合预测模型,提高短期风速预测的准确性与可靠性。文献[31]中提出了台风条件下海上风电场风速多步预测方法,可提升风速变化剧烈场景下的风速预测精度。文献[32]提出了一种基于最小二乘支持向量机的短期风速预测方法。

然而,现有方法仍存在三方面不足:一是多集中于确定性预测,难以刻画阵风内在随机性,缺乏不确定性量化能力;二是时间分辨率不足,对于阵风场景下风速的预测能力不够;三是未考虑引入风机运行状态等进行辅助引导,预测结果精确性受限。

针对上述问题,本文提出一种基于去噪扩散概率模型与Transformer融合(denoising diffusion probabilistic model-transformer,DDPM-Transformer)的秒级阵风风速概率预测方法,并据此设计风电机组

转速备用模式的自适应切换策略。该方法摒弃对宏观气象场缓慢变化的依赖，转而引入反映风机气动、机械与控制特性的多维度实时状态参数，利用上述与风机本体相关的实时状态参数作为辅助条件进行引导。在此基础上，利用蒙特卡罗采样生成概率预测结果，有效表征阵风不确定性，并进一步构建风电机组调频备用模式的动态切换策略，依据高精度风速预测信息实现超速减载与低速减载的最优选择，从而提升风电场调频能力评估的准确性与实时性，为高比例新能源电力系统的频率安全稳定控制提供决策参考。

1　风电机组转子转速备用模式

1.1　风电机组转速备用功率模型

风轮从风中捕获的机械功率，其物理特性一般用式(1)—(4)来描述，具体模型参数详见文献[33]。

$$P_{\mathrm{m}}=\frac{1}{2}\rho\pi R^2C_{\mathrm{p}}(\lambda,\beta)v^3 \tag{1}$$

$$\lambda=\frac{R\omega_{\mathrm{w}}}{v} \tag{2}$$

$$C_{\mathrm{p}}(\lambda,\beta)=0.22\left(\frac{116}{\lambda_{\mathrm{i}}}-0.4\beta-5\right)\mathrm{e}^{\frac{-12.5}{\lambda_{\mathrm{i}}}} \tag{3}$$

$$\lambda_{\mathrm{i}}=\left(\frac{1}{\lambda+0.08\beta}-\frac{0.035}{\beta^3+1}\right)^{-1} \tag{4}$$

式中：P_{m}为风轮捕获的机械功率；ρ为大气密度；R为风机叶片半径；$C_{\mathrm{p}}(\lambda,\beta)$为风机风能利用系数；$v$为风速；$\lambda$为叶尖速比；$\beta$为风机桨距角；$\omega_{\mathrm{w}}$为风机机械转速；$\lambda_{\mathrm{i}}$为叶尖速比中间变量。

由式(1)—(4)可知，风机输出功率可通过调节转子转速或调节桨距角实现。转速控制通过改变叶尖速比进行功率调节，动态响应快，适用于需要频繁快速调节的场景；桨距角控制依赖于机械执行机构，受惯性与延时影响，响应较慢。在风速波动剧烈、阵风频发场景中，变桨机构因慢动态特性难以适用于秒级阵风下的调频。

为此，本文采用基于转子转速的减载控制策略，通过使风机运行于最大风能点跟踪(maximum power point tracking，MPPT)曲线两侧的非最优转速点，即超速减载(over-speed deloading，OSD)与低速减载(under-speed deloading，USD)两种模式来实现功率备用。如图1所示，在相同减载率下，可在最优转速两侧分别确定高速与低速运行点，两者提供一致的备用容量。需说明的是，为保障运行安全，转子转速通常限制在0.8~1.2 pu范围内，在此范围内基于转速的减载控制可适应风况的快速变化，为系统频率提供快速灵活的有功支撑[34]。

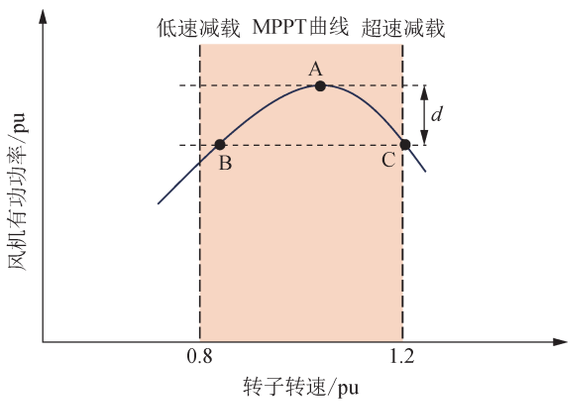


图1　风机转子转速减载控制

Fig. 1　Wind turbine rotor speed deloading control

1.2　OSD与USD模式运行特性及边界分析

为明晰超速减载与低速减载两种减载模式的运行特性与边界，需首先进行风能利用系数与输出功率的建模。

根据式(3)可知，在仅采用转速控制实现减载运行，即固定桨角距$\beta=0°$的条件下，风能利用系数$C_{\mathrm{p}}(\lambda)$可表述为叶尖速比λ的显函数。

$$C_{\mathrm{p}}(\lambda)=0.22\left[116\left(\frac{1}{\lambda}-0.035\right)-5\right]\mathrm{e}^{-12.5\left(\frac{1}{\lambda}-0.035\right)} \tag{5}$$

可得输出功率P_{w}关于风速v与转子转速ω_{r}的表达式：

$$P_{\mathrm{w}}=0.11\rho\pi R^2v^3\left[116\left(\frac{v}{R\omega_{\mathrm{r}}}-0.035\right)-5\right]\mathrm{e}^{-12.5\left(\frac{v}{R\omega_{\mathrm{r}}}-0.035\right)} \tag{6}$$

通过求解$\partial P_{\mathrm{w}}/\partial\omega_{\mathrm{r}}=0$，可确定MPPT模式下对应的最优转速$\omega_{\mathrm{MPPT}}$。

接着进行调频容量与转速运行范围分析，为确保双馈风电机组安全运行，转子转速需约束在0.8~1.2 pu范围内，可用调频容量ΔP定义为当前风速下最大可捕获功率P_{MPPT}与实际输出功率P_{w}之差：

$$\Delta P=P_{\mathrm{MPPT}}-P_{\mathrm{w}}=\frac{1}{2}\rho\pi R^2v^3\left[C_{\mathrm{p,max}}-C_{\mathrm{p}}\left(\frac{R\omega_{\mathrm{r}}}{v}\right)\right] \tag{7}$$

式中：$C_{\mathrm{p,max}}$为MPPT模式下对应的风能利用系数。为评估两种减载模式的最大调频能力，分别计算转速上下限处的容量极值。

OSD最大容量，即令$\omega_{\mathrm{r}}=1.2$ pu时：

$$\Delta P_{\mathrm{OSD}}^{\max}=\frac{1}{2}\rho\pi R^2v^3\left[C_{\mathrm{p,max}}-C_p\left(\frac{1.2R}{v}\right)\right] \tag{8}$$

USD最大容量，即令$\omega_{\mathrm{r}}=0.8$ pu时：

$$\Delta P_{\mathrm{USD}}^{\max}=\frac{1}{2}\rho\pi R^2v^3\left[C_{\mathrm{p,max}}-C_{\mathrm{p}}\left(\frac{0.8R}{v}\right)\right] \tag{9}$$

系统可用的最大调频容量为二者中的较大值：

$$\Delta P^{\max}=\max\left\{\Delta P_{\mathrm{OSD}}^{\max},\Delta P_{\mathrm{USD}}^{\max}\right\} \tag{10}$$

针对计算出的系统可用的最大调频容量进行运行边界划分与模式选择策略分析。不同风速下两种

模式的调频容量特性如图2所示，可制定以下分区控制策略。

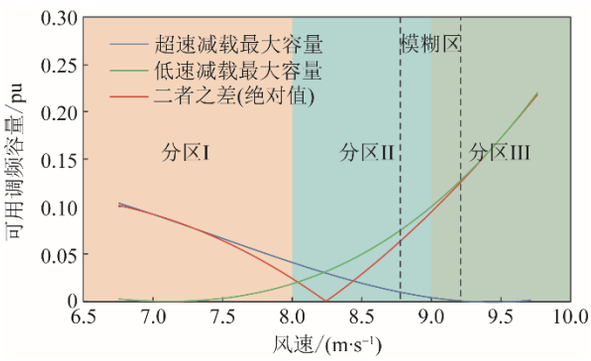


图2 不同风速下两种模式的调频容量特性

Fig. 2 Frequency regulation capacity characteristics of two modes under different wind speeds

当风速低于8.0 m/s，风速处于分区Ⅰ时，OSD可提供的调频容量显著更大，风能损失较小，宜采用OSD模式；当风速处于8.0~9.0 m/s的分区Ⅱ时，两种策略调频容量相近。考虑到OSD在系统功率缺额时可通过转速下降同时提升风能捕获能力和释放转子动能，更有利于频率稳定，故推荐在该区间采用OSD模式；当风速高于9.0 m/s的分区Ⅲ时，USD更具优势，但需将转速严格限制在0.8 pu以上，此时应采用USD模式。

需要注意的是，当风速在分区Ⅱ和分区Ⅲ之间的模糊区频繁波动时，传统基于确定性预测的切换策略难以准确预判阵风的随机性与不确定性，易导致模式切换滞后。同时，该策略在切换阈值附近易产生频繁振荡，引发机组运行模式反复切换，影响控制的稳定性。

为此，本文在实现高精度阵风预测的基础上，提出一种风速自适应的减载模式切换策略，以实现转子转速减载模式的动态优化选择，在确保机组安全运行的前提下，最大限度提升系统的暂态调频能力。

2 基于DDPM-Transformer的阵风风速概率预测模型

2.1 模型整体架构与工作流程

所构建的DDPM-Transformer模型是一个基于条件扩散过程的概率生成模型，其核心思想是将未来阵风预测任务转化为一个序列补全问题。

其中所提模型的改进主要体现在：首先，将未来阵风预测建模为条件扩散生成问题，通过多次反向去噪生成多条未来风速轨迹，而非单一确定性预测值，从而为动态置信走廊和超阈值概率计算提供基础；其次，引入Transformer作为条件去噪网络，以增强模型对秒级阵风突变和短时波动的刻画能力；最后，引入风机状态特征，将有功功率、电机转矩、电机转速、桨距角和有功功率设定值等与风机运行密切相关的变量作为条件信息，利用上述与风机本体相关的实时状态参数进行辅助。通过上述设计，模型输出的预测均值、标准差及置信区间能够进一步转化为切换策略中的概率判据，为转速备用模式由被动式响应向主动式切换提供支撑。

模型通过学习恢复一个被噪声完全破坏的、包含历史与未来时间步的完整序列，从而实现对未来的预测。其整体架构如图3所示，运行流程如下：首先进行完整序列构建，先获取历史风速序列$\boldsymbol{y}_{\mathrm{p}}$和历史风机运行状态参数$\boldsymbol{x}_{\mathrm{p}}$，并将已知的历史风速序列$\boldsymbol{y}_{\mathrm{p}}$与一个待预测的、长度为$T$的空白未来时间窗口进行拼接，构成一个完整的、覆盖历史+未来的目标序列$\boldsymbol{y}_{\mathrm{f}}$；其次对目标序列进行整体加噪，通过多步迭代，向$\boldsymbol{y}_{\mathrm{f}}$中逐渐注入高斯噪声，直至其完全转化为一个纯高斯噪声序列$\boldsymbol{y}_T$；接着对$\boldsymbol{x}_{\mathrm{p}}$进行条件编码并利用编码所得的辅助条件引导向量$\boldsymbol{c}_{\mathrm{emb}}$对$\boldsymbol{y}_T$进行引导去噪，在每一步$t$，Transformer去噪网络都接收当前的含噪完整序列$\boldsymbol{y}_t$以及辅助条件引导向量$\boldsymbol{c}_{\mathrm{emb}}$作为输入，并预测出添加到序列中的噪声。通过逐步减去预测噪声，从而恢复出更清晰的完整序列$\boldsymbol{y}_{t-1}$；最后从完整的去噪序列$\boldsymbol{y}_0$中，分离出未来时间窗口部分，即为一条阵风预测轨迹。

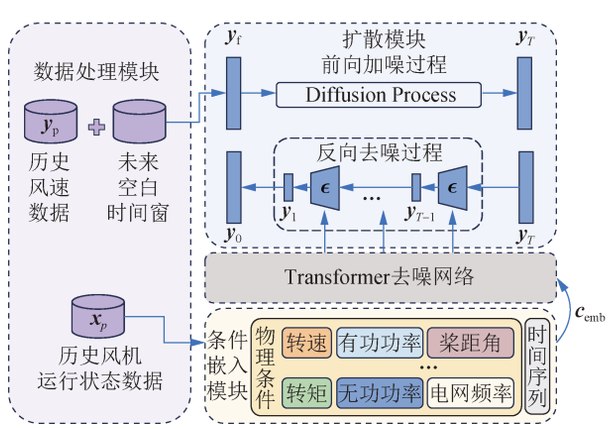


图3 DDPM-Transformer模型整体架构与工作流程图

Fig. 3 DDPM-Transformer architecture and workflow

通过多次重复上述过程，获得一组预测轨迹$\{\boldsymbol{y}_0^{(1)},\boldsymbol{y}_0^{(2)},\cdots\boldsymbol{y}_0^{(K)}\}$，其中$K$为采样轨迹数，从而生成概率性预测结果，用于后续的不确定性分析。

2.2 DDPM-Transformer的模块构成

1）DDPM模块：扩散与生成过程。

DDPM模型是一类先进的深度生成模型，其核心思想是通过一个固定的前向扩散过程对原始数据逐

步加噪，并利用一个可学习的反向去噪过程从噪声中重建数据样本[35-36]。该模型主要包含以下两个过程：

（1）前向加噪过程。

前向过程是一个固定的马尔可夫链，在步长 $t = 0, 1, \cdots, T$ 内，逐步对拼接后的完整目标序列 $\boldsymbol{y}_{\mathrm{f}}$ 添加高斯噪声，产生一系列噪声水平逐渐递增的隐变量 $\boldsymbol{y}_1, \boldsymbol{y}_2, \cdots, \boldsymbol{y}_T$。其数学表达为：

$$q(\boldsymbol{y}_t|\boldsymbol{y}_{t-1}) = \mathcal{N}(\boldsymbol{y}_t;\ \sqrt{1-\beta_t}\,\boldsymbol{y}_{t-1}, \beta_t \boldsymbol{I}) \tag{11}$$

式中：$q(\boldsymbol{y}_t|\boldsymbol{y}_{t-1})$ 为条件概率分布；β_t 为预先定义的噪声方差调度参数，控制着每一步添加的噪声量；$\mathcal{N}(\cdot)$ 为多元高斯分布；$\boldsymbol{I}$ 为单位矩阵。该过程无需学习，其目的是将真实数据分布 $q(\boldsymbol{y}_{\mathrm{f}})$ 逐渐转化为标准高斯分布 $\boldsymbol{y}_T \sim \mathcal{N}(0, \boldsymbol{I})$。

（2）反向去噪过程。

反向过程致力于从 $\boldsymbol{y}_T$ 开始，逐步去除噪声，最终生成逼真的数据样本 $\boldsymbol{y}_0$。每一步由以下参数化的高斯分布定义：

$$p_\theta(\boldsymbol{y}_{t-1}|\boldsymbol{y}_t, \boldsymbol{c}_{\mathrm{emb}}) = \mathcal{N}\left[\boldsymbol{y}_{t-1};\ \boldsymbol{\mu}_\theta(\boldsymbol{y}_t, t, \boldsymbol{c}_{\mathrm{emb}}), \boldsymbol{\Sigma}_\theta(\boldsymbol{y}_t, t, \boldsymbol{c}_{\mathrm{emb}})\right] \tag{12}$$

式中：$\boldsymbol{\mu}_\theta(\cdot)$ 和 $\boldsymbol{\Sigma}_\theta(\cdot)$ 为学习得到的均值和方差；$\boldsymbol{c}_{\mathrm{emb}}$ 为辅助条件引导向量。

实践中，常通过训练一个去噪网络 $\boldsymbol{\epsilon}_\theta$ 来预测在前向过程中第 t 步所添加的噪声 $\boldsymbol{\epsilon}$，进而间接地学习得到 $\boldsymbol{\mu}_\theta$。

2）风机运行状态辅助引导嵌入机制。

该模块的核心功能是将多源异构的历史风机运行状态参数 $\boldsymbol{x}_{\mathrm{p}}$ 编码为一个固定维度的辅助条件引导向量 $\boldsymbol{c}_{\mathrm{emb}}$。

在秒级高分辨率阵风预测任务中，传统基于天气数据的预测方法因气象要素在秒级时间尺度上变化不显著，难以为瞬变阵风预测提供有效指导。为实现秒级阵风的精准预测，必须引入具备相同采样频率的高频动态数据作为输入。目前可用于描述阵风动态的运行状态量有限，多数现有方法仅依赖单通道历史阵风风速序列进行预测，未充分挖掘多源数据中的耦合信息。从时间序列建模角度而言，多通道时序数据有助于神经网络捕捉不同时刻、不同变量间隐含的复杂动态关联，从而提升模型泛化能力与预测精度。

针对上述问题，本文弱化对数值天气预报数据的直接依赖，提出一种融合数据驱动与风机运行状态特征的辅助引导嵌入机制。该机制基于风机运行过程中反映其气动特性、机械响应及控制逻辑的多维度状态参数，构建风机运行状态特征辅助引导的阵风预测模型。具体以风机电机转矩、电机转速、桨距角等关键运行状态量作为条件变量，引导扩散模型生成既符合数据分布又满足风机运行状态特征的阵风序列，从而提升秒级阵风预测的准确性与可解释性。

3）条件化 Transformer 去噪模块。

传统 DDPM 模型常采用 U-Net 作为其去噪网络 $\boldsymbol{\epsilon}_\theta$，然而 U-Net 在捕获长序列依赖关系方面存在固有局限。为提升模型对秒级阵风序列中复杂时序模式的建模能力，本文采用 Transformer 架构作为去噪主干网络，构建条件化去噪函数 $\boldsymbol{\epsilon}_\theta(\boldsymbol{y}_t, t, \boldsymbol{c}_{\mathrm{emb}})$，该网络的核心优势在于其注意力机制，能够同时捕捉序列内部的长程依赖关系并融入外部的条件引导。

3　基于不确定性感知的风电机组自适应切换策略

3.1　风电机组自适应切换决策框架构建

策略总体架构如图 4 所示，通过 DDPM-Transformer 模型生成概率预测序列，将模块 1 输出的预测均值 $\boldsymbol{\mu}_{\mathrm{pred}}$ 和标准差 $\boldsymbol{\sigma}_{\mathrm{pred}}$ 输入到模块 2 中，首先判断是否通过双重校验机制，接着判断风速所处区间，若风速处在保持区，则机组保持原有工作模式；若风速处于模糊区，则进入模块 3 进行决策判断。

3.2　动态置信走廊构建与决策鲁棒性增强机制

首先，基于 DDPM 模型生成的概率预测结果，构建表征未来风速可能波动范围的动态置信走廊：

$$C(t) = \left[L(t), U(t)\right] = \left[\mu_{\mathrm{pred}}(t) - k\sigma_{\mathrm{pred}}(t),\ \mu_{\mathrm{pred}}(t) + k\sigma_{\mathrm{pred}}(t)\right] \tag{13}$$

式中：$L(t)$ 和 $U(t)$ 分别为置信走廊的下界与上界；k 为置信系数（$k = 2$，对应约 95% 的置信水平），该走廊直观反映了未来风速的概率分布范围。

为确保切换决策的稳定可靠，避免因风速瞬时波动导致控制系统频繁误动，本策略集成了时间持久性与迟滞切换的双重鲁棒机制。该设计的核心在于考虑过于频繁的控制指令不仅无法被有效执行，还会对传动链和变流器造成不必要的冲击。

迟滞切换机制主要为了解决在固定切换阈值 v_{th} 附近因风速随机波动而引发的控制指令频繁振荡问题，用以增强切换决策的鲁棒性。该机制通过设定差异化的动作与返回阈值，构建一个稳定的控制不灵敏区，从而有效滤除阈值附近的瞬时波动干扰。定义滞环的上下阈值如下：

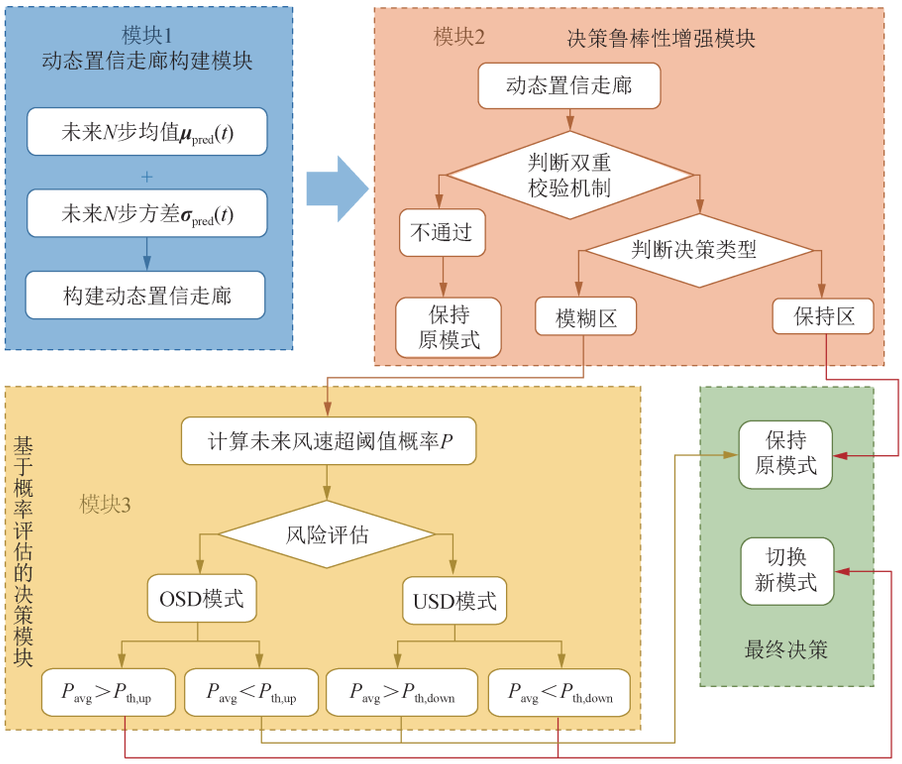


图 4 风电机组自适应切换策略总体架构

Fig. 4 Overall architecture of the adaptive switching strategy for wind turbines

1)动作阈值$v_{th,up}$:当系统运行于超速减载模式时,风速预测值需持续高于此阈值,方可触发向低速减载模式的切换。其计算式为:

$$v_{th,up} = v_{th} + \Delta V \tag{14}$$

2)返回阈值$v_{th,down}$:当系统运行于低速减载模式时,风速预测值需持续低于此阈值,方可返回至超速减载模式。其计算式为:

$$v_{th,down} = v_{th} - \Delta V \tag{15}$$

滞环宽度ΔV是核心设计参数,其取值与风场的湍流强度正相关,通常在0.2~0.5 m/s范围内进行整定,可以进行调节,以期在防抖能力与风能捕获灵敏度之间取得最佳平衡。

时间持久性校验机制要求任何切换决策必须基于一个持续稳定的预测趋势。仅当高置信切换或保持的条件,即$L(t)>v_{th,up}$或$U(t)<v_{th,down}$在未来连续一段时间T_{min}内均被满足时,才会生成最终的切换指令。T_{min}的取值由机组惯量响应持续时间决定:

$$T_{min} = T_{inertia} \tag{16}$$

式中:$T_{inertia}$为机组惯量响应持续时间,该过程约需10 s[37]。

若风速通过双重校验机制则进行风速分区判定,若不通过,则保持原有工作模式。

3.3 风速分区以及基于概率评估的决策模块

以动作阈值$v_{th,up}$以及返回阈值$v_{th,down}$为判据,根据置信走廊与阈值的相对位置关系,可将风机决策区域划分为保持区与决策模糊区。

当置信走廊在未来T_{min}时间内完全位于阈值下方或阈值上方时,即$U(t)<v_{th,down}$或$L(t)>v_{th,up}$,表明未来风速将持续低于切换阈值或高于切换阈值,系统应维持当前模式运行,视为保持区。若未来T_{min}时间内出现置信走廊横跨切换阈值的情况时,即$L(t)<v_{th,up}<U(t)$或$L(t)<v_{th,down}<U(t)$时,则为决策模糊区,表明预测结果存在显著不确定性,风速有可能高于也可能低于阈值。

若风速处在决策模糊区,则进入模块3进行综合判断,决策机制如下:

1)判断风机工作模式。若风机工作在超速减载模式以动作阈值$v_{th,up}$为判据计算未来T_{min}时间内超阈值的概率P_{avg}。

计算未来风速超过阈值的概率为:

$$P[v(t)>v_{th,up}] = 1 - \Phi\left[\frac{v_{th,up} - \mu_{pred}(t)}{\sigma_{pred}(t)}\right] \tag{17}$$

$$P_{avg} = \frac{1}{T_{min}} P[v(t)>v_{th,up}] \tag{18}$$

式中:$\Phi(\cdot)$为标准正态分布函数,若$P_{avg}>P_{th}$则触发由OSD向USD的模式切换,其中概率阈值P_{th}取0.5。

2)判断风机工作模式。若风机工作在低速减载模式,以返回阈值$v_{th,down}$为判据计算未来T_{min}时间内超阈值的概率。

计算未来风速低于阈值的概率为：

$$P[v(t)<v_{\text{th,down}}]=\Phi\left[\frac{v_{\text{th,down}}-\boldsymbol{\mu}_{\text{pred}}(t)}{\boldsymbol{\sigma}_{\text{pred}}(t)}\right] \tag{19}$$

$$P_{\text{avg}}=\frac{1}{T_{\min}}P[v(t)<v_{\text{th,down}}] \tag{20}$$

若$P_{\text{avg}}>P_{\text{th}}$则触发由USD向OSD的模式切换。

4　仿真验证

4.1　实验数据与仿真平台

为验证本文所提方法的有效性，本文基于某海上风电场风机采集与监视控制系统（supervisory control and data acquisition，SCADA）秒级连续采样数据进行仿真，采样率为1 Hz。原始数据共包含86 400个时间样本，记录了风机连续运行过程中的风速及相关运行状态量，既包括中低风速工况，也包括高风速及阵风扰动工况，从而保证了训练与测试样本具有较好的代表性。经预处理后，采用滑动时间窗方式构造预测模型的输入输出样本，以前180 s历史序列作为输入、未来30 s风速序列作为输出，并按7∶2∶1划分为训练集、验证集和测试集。测试阶段，DDPM模型为每个样本生成多条预测序列以评估其概率预测性能。模型的辅助引导条件为包含5D运行状态量的风机状态向量，具体包括：有功功率、电机转矩、电机转速、桨距角及有功功率设定值。所提预测模型均在Python环境下开发，使用PyTorch框架实现。对比模型选取具有代表性的时序深度学习方法：

1）LSTM：具有长期记忆能力的递归神经网络；

2）TCN：基于因果卷积的时序模型，具有并行化优势与长程依赖捕捉能力。

4.2　阵风预测性能分析

为全面评估所提模型的预测性能，本文采用的评估指标包括均方根误差（root mean square error，RMSE）R_{RMSE}、平均绝对误差（mean absolute error，MAE）R_{MAE}、平均绝对百分比误差（mean absolute percentage error，MAPE）R_{MAPE}和决定系数R^2，定义如下：

$$\begin{cases}R_{\text{RMSE}}=\sqrt{\dfrac{1}{n}\sum\limits_{i=1}^{n}(y_i-\hat{y}_i)^2}\\ R_{\text{MAE}}=\dfrac{1}{n}\sum\limits_{i=1}^{n}\left|y_i-\hat{y}_i\right|\\ R_{\text{MAPE}}=\dfrac{1}{n}\sum\limits_{i=1}^{n}\left|\dfrac{y_i-\hat{y}_i}{y_i}\right|\times 100\%\\ R^2=1-\dfrac{\sum\limits_{i=1}^{n}(y_i-\hat{y}_i)^2}{\sum\limits_{i=1}^{n}(y_i-\bar{y})^2}\end{cases} \tag{21}$$

式中：y_i是真实值；$\bar{y}$是真实值的均值；$\hat{y}_i$是预测值；n是样本数量。各模型在测试集上的性能指标如表1所示。

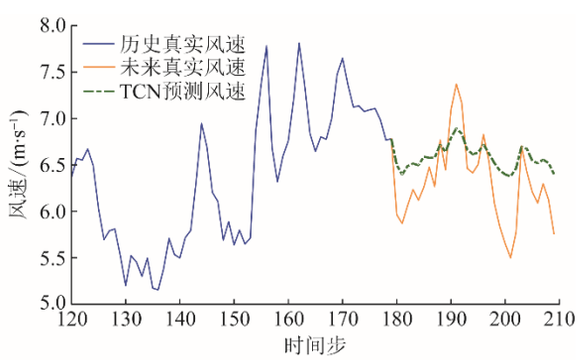
表1　阵风场景下不同模型风速预测结果对比

Table 1　Comparison of wind speed prediction results of different models under gust scenarios

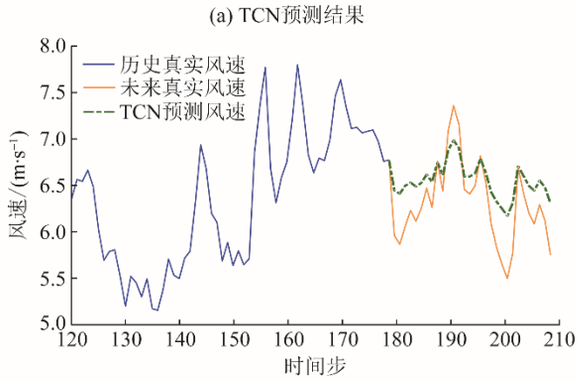
模型	R_{RMSE}/(m/s)	R_{MAE}/(m/s)	R_{MAPE}/%	R^2
所提方法	0.199 2	0.162 0	1.410 3	0.966 1
LSTM	1.081 0	0.932 7	8.085 1	0.841 7
TCN	1.275 0	1.067 2	9.274 5	0.814 6

结果表明，DDPM-Transformer在确定性预测指标上显著优于对比模型。为与传统确定性模型公平比较，此处将所提方法生成轨迹的中位数作为预测值进行评估。具体而言，所提方法的R_{RMSE}为0.199 2 m/s，较LSTM和TCN分别降低81.57%和84.38%；R_{MAE}为0.162 0 m/s，较LSTM和TCN分别降低82.63%和84.82%；R_{MAPE}为1.410 3%，较LSTM和TCN均有明显降低。同时，其R^2达到0.966 1，表明预测值与真实值高度吻合。

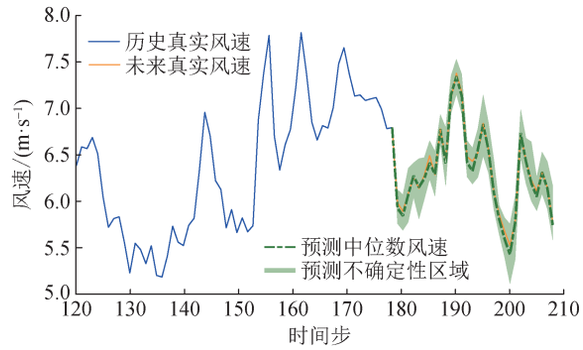
如图5中（a）—（c）所示，LSTM和TCN的输出呈现平滑化趋势，难以充分捕捉秒级风速波动；而DDPM-Transformer的预测区间能够有效包络真实风速曲线，体现出对阵风不确定性的刻画能力。在概率预测方面，DDPM-Transformer能够通过多次采样生成未来风速的预测分布。如图5中（d）所示，该模型所生成的预测带宽较窄，中位数预测曲线与真实值基本重合，说明模型在准确预测的同时具备较好的不确定性刻画能力。其概率预测性能将在4.4节中进一步通过概率预测模型对比实验进行分析。



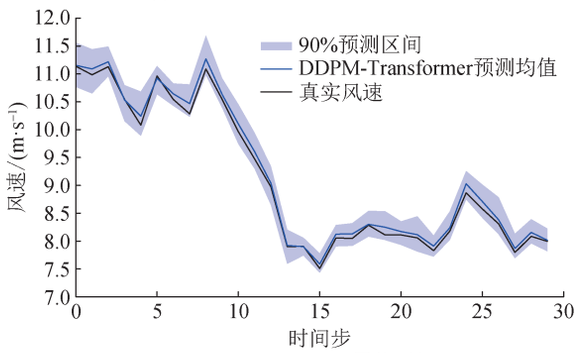
(a) TCN预测结果



(b) LSTM预测结果



(c) DDPM-Transformer预测结果



(d) DDPM-Transformer置信区间

图5 阵风场景下不同模型预测结果

Fig. 5 Prediction results of different models under gust scenarios

上述分析表明，所提DDPM-Transformer模型通过扩散过程有效建模了风速序列的随机性和非线性特征，在阵风等极端工况下具备更强的瞬变捕捉能力，能够为风电机组备用功率控制提供高精度的前瞻性风速信息，满足秒级调频控制对预测时效性和准确性的严格要求。

4.3 消融实验

为分析所提方法性能提升的具体来源，本文进一步开展消融实验，从风机状态辅助引导模块和去噪主干网络两个维度进行验证，结果如表2所示。具体对比模型设置如下：

1）无条件DDPM-Transformer：去除风机状态辅助引导信息，仅保留扩散生成与Transformer去噪结构，用于验证条件引导信息的作用；

2）条件DDPM-U-Net：保留辅助条件引导，但将去噪主干由Transformer替换为传统U-Net，用于验证Transformer去噪网络的贡献；

3）完整DDPM-Transformer：即本文所提模型。

由表2可见，完整的DDPM-Transformer模型在R_{RMSE}、R_{MAE}、R_{MAPE}和R^2等指标上均取得较好结果。辅助条件引导机制和Transformer去噪主干均对所提模型的性能提升具有重要贡献。

4.4 概率预测性能对比分析

为进一步验证所提模型在概率预测与不确定性建模方面的优势，本文在确定性预测对比实验的基础上，补充选取蒙特卡罗暂退法长短期记忆网络（Monte Carlo dropout long short-term memory，MC-Dropout LSTM）和分位数回归长短期记忆网络（quantile regression long short-term memory，QR-LSTM）两类典型概率预测方法作为对比模型：

表2 阵风场景下消融实验结果对比

Table 2 Comparison of ablation experiment results in gust scenarios

模型	R_{RMSE}/(m/s)	R_{MAE}/(m/s)	R_{MAPE}/%	R^2
无条件DDPM-Transformer	0.952 8	0.847 7	7.348 0	0.855 8
条件DDPM-U-Net	0.785 1	0.657 3	5.691 7	0.883 5
所提方法	0.199 2	0.162 0	1.410 3	0.966 1

1）MC-Dropout LSTM：在LSTM网络中引入Dropout机制，通过多次随机前向传播近似贝叶斯推理，量化预测的不确定性；

2）QR-LSTM：在LSTM中引入分位数回归，通过输出不同分位水平下的预测分位数构造预测区间。

为保证对比实验的公平性，各概率预测模型均采用与所提模型相同的数据集划分方式、输入历史窗口和预测时间窗口，即以前180 s历史序列作为输入，预测未来30 s风速序列。本节实验沿用4.1节所述数据集与预处理方式。

为评估模型概率预测性能，本文采用的评估指标包括：连续分级概率评分（continuous ranked probability score，CRPS）R_{CPRS}、90%预测区间覆盖率（prediction interval coverage probability，PICP）R_{PICP}和90%归一化预测区间宽度（prediction interval normalized average width，PINAW）R_{PINAW}。具体定义如下：

$$\begin{cases} R_{\mathrm{CRPS}}(F, y_{\mathrm{obs}}) = \int_{-\infty}^{\infty} \left[F(x) - \mathrm{II}(x \geqslant y_{\mathrm{obs}}) \right]^2 \mathrm{d}x \\ R_{\mathrm{PICP}} = \dfrac{1}{N} \sum_{t=1}^{N} \mathrm{II}(L_t \leqslant y_m \leqslant U_t) \\ R_{\mathrm{PINAW}} = \dfrac{1}{NR} \sum_{t=1}^{N} (U_t - L_t) \\ R = y_{\max} - y_{\min} \end{cases} \tag{22}$$

式中：$F(\cdot)$为预测累积分布函数；x为积分变量；y_{obs}为观测值；$\mathrm{II}(\cdot)$为指示函数；N为测试集的样本总数；y_m为第m个样本的真实观测值；L_t为第t个样本预测区间的下界；U_t为第t个样本预测区间的上界；R为目标变量取值范围；$y_{\max}$为观测值的最大值；$y_{\min}$为观测值的最小值。

R_{CRPS}用于综合衡量预测分布与真实观测值之间的偏差，值越小表示概率预测性能越优；R_{PICP}用于衡

量真实风速落入预测区间的比例，反映预测区间的可靠性；R_{PINAW}用于衡量预测区间的归一化平均宽度，反映预测区间的尖锐性。在概率预测任务中，理想模型应在获得较低R_{CRPS}的同时，兼顾较高的区间覆盖率和较窄的预测区间宽度。

不同概率预测模型在测试集上的性能对比如表3所示。

表3　阵风场景下不同概率预测模型性能对比

Table 3　Comparison of probabilistic prediction performance of different models in gust scenarios

模型	R_{CPRS}	90%R_{PICP}	90%R_{PINAW}
MC-Dropout LSTM	0.314 5	0.622 0	0.080 6
QR-LSTM	0.255 8	0.893 6	0.115 4
所提方法	0.060 6	0.989 2	0.038 8

由表3可见，所提DDPM-Transformer模型在R_{CRPS}指标上取得最低值，为0.060 6，较MC-Dropout LSTM、QR-LSTM分别降低80.73%和76.31%，说明其预测分布与真实风速观测值之间的整体偏差更小，能够更准确地刻画阵风场景下未来风速的不确定性。

从预测区间指标来看，所提模型的90%R_{PICP}达到0.989 2，高于MC-Dropout LSTM的0.622 0和QR-LSTM的0.893 6，说明其预测区间能够更有效地覆盖真实风速变化。同时，所提模型的90%R_{PINAW}仅为0.038 8，低于MC-Dropout LSTM的0.080 6和QR-LSTM的0.115 4，表明所提模型在保持较窄预测区间的同时实现了更高的覆盖能力。

为进一步直观展示不同概率预测模型预测区间的差异，本文选取测试集中典型样本绘制3类模型90%预测区间叠加对比图，如图6所示。

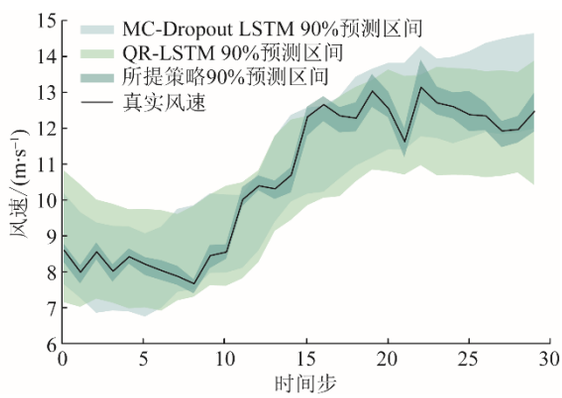


图6　不同概率预测模型90%预测区间对比

Fig. 6　Comparison of 90% prediction intervals across models

综合R_{CRPS}、R_{PICP}和R_{PINAW}结果可知，DDPM-Transformer在概率预测精度、区间可靠性和区间尖锐性之间取得了更优平衡，进一步验证了所提方法在阵风风速概率预测任务中的有效性。

4.5　基于不同预测模型的自适应切换策略性能对比

为验证DDPM-Transformer模型在所提不确定性感知自适应切换策略下的良好性能，实验基于前文海上风电场SCADA实测数据开展，样本覆盖风电场典型运行工况及阵风扰动场景。为实现时间持久性校验和决策防抖动，按前文所述取T_{min} = 10 s，ΔV = 0.3 m/s。

为确保对比的公平性，所有模型均采用统一的切换决策框架，即将各模型的预测输出嵌入到式(17)—(20)所定义的概率评估机制中，并辅以3.2节提出的时间持久性校验与迟滞控制，以形成最终的切换指令。

实验对比了3类预测模型：本文提出的DDPM-Transformer概率预测模型，以及LSTM和TCN确定性预测模型。所有模型均采用统一的输入/输出结构，即利用过去180 s的历史数据，对未来T_{min}时间窗内的风速进行滚动预测。

各类模型与概率决策框架的结合方式具体如下：

1）DDPM-Transformer概率预测模型：模型通过多次采样生成未来风速预测轨迹，并由样本统计得到未来各时刻风速的预测均值$\mu_{pred}(t)$与方差$\sigma_{pred}(t)$。根据风机的工作模式，可直接计算出每个未来时刻t的风速超过/低于风速切换阈值概率。随后，依据对应的式(18)或式(20)计算在未来T_{min}时间窗内的平均概率P_{avg}，并与概率阈值P_{th}比较，以作出切换决策。

2）LSTM/TCN确定性预测模型：此类模型仅输出未来各时刻的单一预测值$v_{pred}(t)$。为将其适配于概率决策框架，其确定性预测结果被转化为一种二元概率形式：在任一未来时刻t，若预测值$v_{pred}(t)$超过风速阈值，则认为其超阈值概率为1，否则为0。基于此二元概率序列，同样可利用式(18)或式(20)计算出P_{avg}。在此情景下，P_{avg}的意义转变为预测风速超出阈值的时长占比。

需要说明的是，针对窗口内有多个满足切换条件的切换点时，以第一个切换点为准进行切换，后续只有当模式发生改变时再进行切换。通过上述设计，本节得以在统一的决策基准下，对不同预测模型在预测可靠性、时效性及响应精度等工程关键指标上进行公平、深入的比较，实验结果详见表4。

表 4 切换策略性能对比结果

Table 4 Performance comparison of switching strategies

模型	时效性/s	预测可靠性/%	响应精度/%
所提方法	−3.6	95.3	92.4
LSTM	−2.2	80.9	66.4
TCN	−1.5	75.5	61.0

预测可靠性指预测模型输出结果与实际观测值之间的一致性与可信程度，是决定切换策略性能的关键基础。针对 DDPM-Transformer 概率预测模型，采用置信区间可靠性评估方法进行验证，结果表明，当实际风速超过阈值时，预测置信下界超过设定阈值的概率达到 95.3%；而针对 LSTM、TCN 等确定性预测模型，采用点预测准确率评估方法，其准确率分别为 80.9% 和 75.5%。对比分析显示，DDPM 模型在关键决策阈值下的预测可靠性显著优于确定性预测方法，体现了概率预测在不确定环境下相对于传统确定性预测的优越性，为后续智能切换决策奠定了可靠的理论基础。

时效性方面，DDPM 概率预测模型切换点比满足切换条件的真实切换点平均提前 3.6 s，LSTM 模型比满足切换条件的真实切换点平均提前 2.2 s，TCN 模型比满足切换条件的真实切换点平均提前 1.5 s。

响应精度方面，本文将其定义为正确切换次数与应该切换的总次数之比，计算方法为：正确切换次数/应该切换的总次数×100%。基于该定义，DDPM 模型的响应精度达到 92.4%，显著优于 LSTM 和 TCN 的响应精度。较高的响应精度表明该方法能够更准确地识别出需要切换的工况，从源头上降低误报风险。

综上所述，基于概率预测的自适应切换策略在预测可靠性、响应精度与控制稳定性方面均显著优于确定性预测方法，实现了从确定性判断到概率化决策的跨越，为风电场参与电网频率调节提供了更智能、更鲁棒的控制策略。

4.6 不确定性感知自适应切换策略时效性可视化

本节选取典型阵风事件样本 29 进行可视化分析。如图 7 所示，基于 DDPM-Transformer 的不确定性感知自适应切换机制能够在模糊决策区域内对未来风速超越阈值的概率进行量化评估，从而体现出所提自适应切换决策在前瞻性方面的优势。在模糊区内，策略通过对未来风速超越阈值的概率进行量化评估，实现了从被动响应到主动预判的转换。在典型的阵风工况下，该模型成功预判了即将到来的风速爬升，并前瞻性地触发了模式切换。

通过主动的控制行为，对于提高风机在阵风场景下的备用功率裕度、提升电网频率稳定性具有积极意义。

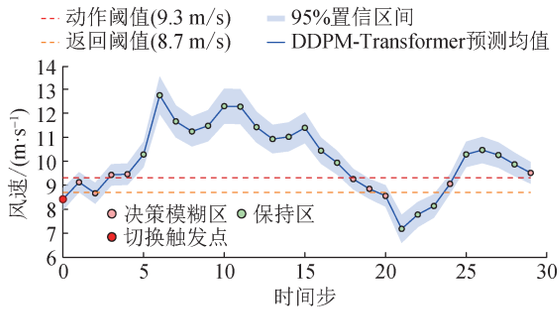


图 7 DDPM-Transformer 自适应切换决策

Fig. 7 DDPM-Transformer adaptive switching decision

5 结 论

在风电渗透率提高导致系统惯量下降的背景下，本文针对阵风环境下风电机组的动态切换策略开展了一系列理论与方法研究，主要研究如下：

1）提出基于 DDPM-Transformer 的秒级阵风概率预测模型，结合扩散过程与注意力机制，有效捕捉阵风瞬变特性。仿真结果表明，所提模型在点预测指标上优于 LSTM 和 TCN 确定性预测方法；同时，模型可通过多次采样生成概率预测轨迹，为后续动态置信走廊构建及不确定性感知切换决策提供前瞻信息。

2）设计基于动态置信走廊与概率评估的自适应切换策略，实现阵风工况下的智能预判与鲁棒决策。仿真表明，所提策略平均切换点较真实条件提前 3.6 s，预测可靠性、响应精度分别达 95.3% 与 92.4%，实现了从“被动响应”到“主动预判”的转换，并通过持久性校验与防抖动策略抑制误动，提升工程适用性。

3）仿真实验验证了所提方法的综合性能优势。结果表明，DDPM-Transformer 在确定性预测、概率预测及消融实验中的各项指标均表现出较优性能。所提模型与不确定性感知切换策略可有效提升风电机组在阵风工况下的适应性与控制鲁棒性，为风电机组参与系统频率调节提供了可行方案。

未来研究将围绕风电场集群协同控制、工程化应用等方面进一步展开。

利益冲突声明（Conflict of Interests）：

所有作者声明不存在利益冲突。

作者贡献声明（Authors' Contributions）：

胡张勤和王镜毓提出研究方向，设计论文框架；黄思哲和黄轶翔设计研究思路，实施研究过程；胡张勤、王镜毓、石东源、姚伟参与了论文写作和修订。

所有作者均阅读并同意了论文终稿内容。

6　参考文献

[1] 康重庆，姚良忠．高比例可再生能源电力系统的关键科学问题与理论研究框架[J]．电力系统自动化，2017，41(9)：1-11.
Kang Chongqing，Yao Liangzhong．Key scientific issues and theoretical research framework for power systems with high proportion of renewable energy[J]．Automation of Electric Power Systems，2017，41(9)：1-11.

[2] 黄雨涵，丁涛，李雨婷，等．碳中和背景下能源低碳化技术综述及对新型电力系统发展的启示[J]．中国电机工程学报，2021，41(增刊1)：28-51.
Huang Yuhan，Ding Tao，Li Yuting，et al．Decarbonization technologies and inspirations for the development of novel power systems in the context of carbon neutrality[J]．Proceedings of the CSEE，2021，41(S1)：28-51.

[3] 杨天蒙，孙霈盈，刘继成，等．考虑支撑能力和调频需求的风电机组动态惯量控制方法[J]．广东电力，2025，38(8)：53-62.
Yang Tianmeng，Sun Peiying，Liu Jicheng，et al．Dynamic virtual inertia control strategy for wind turbines considering supporting capacity and frequency modulation requirements[J]．Guangdong Electric Power，2025，38(8)：53-62.

[4] 刘林，王大龙，綦晓，等．基于双锁相环的海上风场综合惯量调频策略研究[J]．发电技术，2024，45(2)：282-290.
Liu Lin，Wang Dalong，Qi Xiao，et al．Study on double phase-locked loop on the synthetic inertia control of offshore wind farm frequency regulation[J]．Power Generation Technology，2024，45(2)：282-290.

[5] 辛悦，彭乔，刘天琪，等．基于周期性最大功率点检测的风电机组功率备用控制方法[J]．电力自动化设备，2024，44(2)：103-109，116.
Xin Yue，Peng Qiao，Liu Tianqi，et al．Power reserve control method of wind turbine units based on periodic maximum power point measurement[J]．Electric Power Automation Equipment，2024，44(2)：103-109，116.

[6] 张龙，孙丹，年珩，等．计及转速下限和频率安全约束的风电调频参数整定方法[J]．电力工程技术，2025，44(5)：25-34.
Zhang Long，Sun Dan，Nian Heng，et al．Parameter tuning method of frequency regulation for wind power considering rotor speed limit and frequency safety constraint[J]．Electric Power Engineering Technology，2025，44(5)：25-34.

[7] 马覃峰，安甦，刘明顺，等．考虑风光储调频贡献度的新型电力系统频率特性[J]．南方电网技术，2024，18(11)：129-140.
Ma Qinfeng，An Su，Liu Mingshun，et al．Frequency characteristics of new power system considering the frequency modulation contribution of wind power-photovoltaic-energy storage[J]．Southern Power System Technology，2024，18(11)：129-140.

[8] 李阳，李群，陈载宇，等．面向电网最大频率偏差的风电机组短时频率支撑最优策略与机理[J]．中国电机工程学报，2024，44(3)：1020-1034.
Li Yang，Li Qun，Chen Zaiyu，et al．Maximum-frequency-deviation-oriented optimal short-term frequency support strategy of wind turbines and the mechanism[J]．Proceedings of the CSEE，2024，44(3)：1020-1034.

[9] 马宁宁，谢小荣，贺静波，等．高比例新能源和电力电子设备电力系统的宽频振荡研究综述[J]．中国电机工程学报，2020，40(15)：4720-4731.
Ma Ningning，Xie Xiaorong，He Jingbo，et al．Review of wide-band oscillation in renewable and power electronics highly integrated power systems[J]．Proceedings of the CSEE，2020，40(15)：4720-4731.

[10] Ju L W，Tan Z F，Yuan J Y，et al．A bi-level stochastic scheduling optimization model for a virtual power plant connected to a wind-photovoltaic-energy storage system considering the uncertainty and demand response[J]．Applied Energy，2016，171：184-199.

[11] 曲建璋，丁浩天，王毓琦，等．计及风电机组短时过载能力的风电场多机协同频率控制策略[J]．山东电力技术，2024，51(10)：1-9.
Qu Jianzhang，Ding Haotian，Wang Yuqi，et al．Multiple turbines coordinated frequency control strategy for a wind farm considering the short-term overload capacity of wind turbines[J]．Shandong Electric Power，2024，51(10)：1-9.

[12] 邵宜祥，刘剑，胡丽萍，等．一种改进组合神经网络的超短期风速预测方法研究[J]．发电技术，2024，45(2)：323-330.
Shao Yixiang，Liu Jian，Hu Liping，et al．Research on an ultra-short-term wind speed prediction method based on improved combined neural networks[J]．Power Generation Technology，2024，45(2)：323-330.

[13] 李咸善，宋国栋，刘颂凯，等．考虑风储调频协同优化控制的储能调频容量配置[J]．中国电机工程学报，2026，46(13)：5474-5487.
Li Xianshan，Song Guodong，Liu Songkai，et al．Configuration of energy storage frequency regulation capacity considering wind-storage frequency regulation cooperative optimization control[J]．Proceedings of the CSEE，2026，46(13)：5474-5487.

[14] 黄思哲，裴建华，王镜毓，等．计及尾流效应的海上风电场风速重构与动态调频能力评估[J]．电力自动化设备，2025，45(12)：91-98.
Huang Sizhe，Pei Jianhua，Wang Jingyu，et al．Capability assessment of wind speed reconstruction and dynamic frequency regulation for offshore wind farm under wake effect consideration[J]．Electric Power Automation Equipment，2025，45(12)：91-98.

[15] 颜湘武，王德胜，杨琳琳，等．直驱风机惯量支撑与一次调频协调控制策略[J]．电工技术学报，2021，36(15)：3282-3292.
Yan Xiangwu，Wang Desheng，Yang Linlin，et al．Coordinated control strategy of inertia support and primary frequency regulation of PMSG[J]．Transactions of China Electrotechnical Society，2021，36(15)：3282-3292.

[16] 王同森，张峰，丁磊．考虑最优运行点的超速风电机组调频控

制策略[J]. 电力自动化设备，2021，41(6)：22-27.
Wang Tongsen，Zhang Feng，Ding Lei. Frequency regulation control strategy of over-speed wind turbines considering optimal operation point[J]. Electric Power Automation Equipment，2021，41(6)：22-27.

[17] 李生虎，王鹏飞，朱国伟. 考虑双馈异步发电机转速限制的电网频率协调控制策略[J]. 电力系统保护与控制，2017，45(18)：82-87.
Li Shenghu，Wang Pengfei，Zhu Guowei. Coordinated grid frequency control strategy of doubly-fed induction generator considering its rotor speed constraints[J]. Power System Protection and Control，2017，45(18)：82-87.

[18] 金泳霖，戈阳阳，晁璞璞，等. 基于系统功率扰动程度的风电机组主动频率支撑控制策略[J]. 电力系统保护与控制，2025，53(14)：49-58.
Jin Yonglin，Ge Yangyang，Chao Pupu，et al. Wind turbine active frequency support control strategy based on system power disturbance severity [J]. Power System Protection and Control，2025，53(14)：49-58.

[19] 李丰能，杨苹，隗知初，等. 考虑风机调频能量差异的风电场频率主动支撑控制策略[J]. 电力建设，2025，46(11)：145-157.
Li Fengneng，Yang Ping，Kui Zhichu，et al. Active frequency support control strategy for wind farm considering the energy discrepancy of wind turbines [J]. Electric Power Construction，2025，46(11)：145-157.

[20] 张蕊，李晓明，高泽明，等. 考虑风速差异的风电场调频备用协调控制策略[J]. 电力建设，2023，44(2)：101-109.
Zhang Rui，Li Xiaoming，Gao Zeming，et al. Coordinated control of frequency-regulation reserve capacity for wind farm considering wind speed difference[J]. Electric Power Construction，2023，44(2)：101-109.

[21] 何廷一，孙领，李胜男，等. 考虑风速差异的风电场减载方案与一次调频策略[J]. 电力建设，2022，43(7)：139-148.
He Tingyi，Sun Ling，Li Shengnan，et al. Research on deloading scheme and primary frequency regulation strategy of wind farm considering wind speed difference [J]. Electric Power Construction，2022，43(7)：139-148.

[22] 彭海涛，何山，袁至，等. 基于改进转子转速和桨距角协调控制的变速风电机组一次调频策略[J]. 电力自动化设备，2023，43(9)：87-94.
Peng Haitao，He Shan，Yuan Zhi，et al. Primary frequency regulation strategy for variable-speed wind turbines based on improved coordinated control of rotor speed and pitch angle [J]. Electric Power Automation Equipment，2023，43(9)：87-94.

[23] 何欣，钟诚，拜润卿，等. 基于修改功率跟踪特性曲线的风电机组减载调频策略研究[J]. 智慧电力，2021，49(8)：39-45.
He Xin，Zhong Cheng，Bai Runqing，et al. Load reduction frequency modulation strategy of wind turbine based on modifying power tracking characteristic curve [J]. Smart Power，2021，49(8)：39-45.

[24] 赖业宁，颜云松，薛峰，等. 考虑最大转子动能储备的直驱式风力发电机组群优化控制[J]. 电气自动化，2022，44(6)：19-21.
Lai Yening，Yan Yunsong，Xue Feng，et al. Optimal control of direct-drive wind turbine units considering maximum rotor kinetic energy reserve[J]. Electrical Automation，2022，44(6)：19-21.

[25] 王乐，蔺红. 减载风电机组协调控制策略及PI参数优化[J]. 控制工程，2021，28(4)：744-750.
Wang Le，Lin Hong. Coordinated control strategy and PI parameter optimization of load shedding wind turbine[J]. Control Engineering of China，2021，28(4)：744-750.

[26] 冀宵玉，李岩，孙琦，等. 高湍流低风速下风电机组主动减载控制策略研究[J]. 电气自动化，2022，44(6)：7-9.
Ji Xiaoyu，Li Yan，Sun Qi，et al. Research on active load shedding control strategy of wind turbine unit under high turbulence and low wind speed [J]. Electrical Automation，2022，44(6)：7-9.

[27] Zhang Z W，Lin L L，Gao S，et al. A machine learning model for hub-height short-term wind speed prediction [J]. Nature Communications，2025，16：3195.

[28] Sun J，Hu R，Guo L Q. Wind power ultra-short-term instantaneous prediction based on spatiotemporal BP neural network parameter optimization and error correction unit [J]. Processes，2025，13(10)：3248.

[29] 班潇璇，李少林，李庆，等. 基于秒级风速预测的风电频率主动支撑能力动态评估[J]. 电力自动化设备，2025，45(7)：54-60，70.
Ban Xiaoxuan，Li Shaolin，Li Qing，et al. Dynamic evaluation of wind power active frequency support capability based on second-level wind speed forecast [J]. Electric Power Automation Equipment，2025，45(7)：54-60，70.

[30] 谭啸，邱攀，李立，等. 基于多特征数据与混合模型短期风速预测研究[J]. 电工材料，2024(3)：58-62，66.
Tan Xiao，Qiu Pan，Li Li，et al. Short term wind speed prediction based on multi-feature data and mixed model [J]. Electrical Engineering Materials，2024(3)：58-62，66.

[31] 何锦华，刘洋，朱誉，等. 融合物理信息的TPA-LSTM网络应用于台风条件下海上风电场风速多步预测[J]. 电网技术，2023，47(10)：4152-4160.
He Jinhua，Liu Yang，Zhu Yu，et al. Physics-informed TPA-LSTM network applied to multi-step wind speed prediction of offshore wind farms under typhoon conditions [J]. Power System Technology，2023，47(10)：4152-4160.

[32] 莫如发. 基于相空间重构和LSSVM的短期风速预测[J]. 电工技术，2022(18)：54-58.
Mo Rufa. Short term wind speed prediction based on phase space reconstruction and LSSVM [J]. Electric Engineering，2022(18)：54-58.

[33] 秦超，曾沅，苏寅生，等. 基于安全域的大规模风电并网系统低频振荡稳定分析[J]. 电力自动化设备，2017，37(5)：100-106.
Qin Chao，Zeng Yuan，Su Yinsheng，et al. Low-frequency oscillatory stability analysis based on security region for power system with large-scale wind power[J]. Electric Power Automation

Equipment, 2017, 37(5): 100-106.

[34] 王同森，程雪坤. 计及转速限值的双馈风机变下垂系数控制策略[J]. 电力系统保护与控制，2021，49(9)：29-36.
Wang Tongsen, Cheng Xuekun. Variable droop coefficient control strategy of a DFIG considering rotor speed limit[J]. Power System Protection and Control, 2021, 49(9): 29-36.

[35] 李雨婷，刘俊，刘嘉诚，等. 基于去噪扩散概率模型不平衡样本增强的暂态稳定评估[J]. 电力系统自动化，2024，48(21)：148-157.
Li Yuting, Liu Jun, Liu Jiacheng, et al. Transient stability assessment based on imbalanced sample enhancement of denoising diffusion probabilistic model[J]. Automation of Electric Power Systems, 2024, 48(21): 148-157.

[36] 刘锦翔，张江丰，董山玲，等. 基于条件增强扩散模型的短期负荷概率预测[J]. 电力系统自动化，2024，48(23)：197-207.
Liu Jinxiang, Zhang Jiangfeng, Dong Shanling, et al. Short-term load probabilistic forecasting based on conditional enhanced diffusion model[J]. Automation of Electric Power Systems, 2024, 48(23): 197-207.

[37] 王瑞明，徐浩，秦世耀，等. 风电场一次调频分层协调控制研究与应用[J]. 电力系统保护与控制，2019，47(14)：50-58.
Wang Ruiming, Xu Hao, Qin Shiyao, et al. Research and application on primary frequency regulation of wind farms based on hierarchical coordinated control[J]. Power System Protection and Control, 2019, 47(14): 50-58.

收稿日期：2026-04-30　**修回日期**：2026-06-22


胡张勤

作者简介：

胡张勤(2001)，男，硕士研究生，主要研究方向为海上风机有功支撑能力评估；

王镜毓(1993)，男，博士，副研究员，通信作者，主要研究方向为电力系统智能分析计算、电力信息物理安全防御，E-mail：jywang@hust.edu.cn；

黄思哲(2000)，男，博士研究生，主要研究方向为低惯量电力系统频率动态特性分析、新能源集群主动频率支撑能力评估；

黄轶翔(2001)，男，硕士研究生，主要研究方向为新能源与负荷功率预测；

石东源(1974)，男，博士，教授，研究方向为电力系统软件技术、电力系统信息安全、电力系统分析计算；

姚伟(1983)，男，博士，教授，研究方向为含高比例新能源的交直流电力系统稳定分析与控制、新一代电力人工智能技术及应用等。

（编辑　孙静琳）