

深度集成风速驱动的风电功率预测

沈 瑞¹, 李君仪², 张 鹏¹, 王馨若³, 朱振海³, 马子旭¹, 赵学靖^{2*}

¹中广核甘肃民勤第二风力发电有限公司, 甘肃 武威

²兰州大学数学与统计学院, 甘肃 兰州

³甘肃轩岳生态科技有限公司, 甘肃 兰州

收稿日期: 2026年6月27日; 录用日期: 2026年7月19日; 发布日期: 2026年7月29日

摘 要

风电功率预测是风电场优化发电计划、减少弃风并提高经济效益的有效手段, 而精准风速预测是功率预测的关键。本文提出深度集成风速驱动的物理约束共形功率模型以达到对风电功率的精准预测。该模型首先采用长短期记忆神经网络、时间卷积网络和Transformer的深度集成并由XGBoost堆叠估计当前风速, 保证多日滚动时风速输入的时序连续; 进而在风速与功率映射上构造单调物理功率曲线, 之后叠加XGBoost残差学习, 结合分位数回归和分割共形方法给出具备置信度控制的功率预测区间。真实风电场预测及对比实验结果显示, 该模型有效提升了风电功率预测的精度, 区间覆盖率更稳定。且模型能利用该优势将预测区间直接转化为爬坡骤降预警信号, 为风电场运维决策提供物理一致性且工程可用的出力预测方案。

关键词

风电功率预测, 风速深度集成预测模型, 残差学习, 分割共形, 爬坡骤降预警

A Deep Ensemble Wind-Speed-Driven Wind Power Forecasting

Rui Shen¹, Junyi Li², Peng Zhang¹, Xinruo Wang³, Zhenhai Zhu³, Zixu Ma¹, Xuejing Zhao^{2*}

¹CGN Gansu Minqin No. 2 Wind Power Generation Co., Ltd., Wuwei Gansu

²School of Mathematics and Statistics, Lanzhou University, Lanzhou Gansu

³Gansu Xuanyue Ecological Technology Co., Ltd., Lanzhou Gansu

Received: June 27, 2026; accepted: July 19, 2026; published: July 29, 2026

Abstract

Wind power forecasting is an effective means for wind farms to optimize power generation plans,

*通讯作者。

文章引用: 沈瑞, 李君仪, 张鹏, 王馨若, 朱振海, 马子旭, 赵学靖. 深度集成风速驱动的风电功率预测[J]. 统计学与应用, 2026, 15(7): 188-203. DOI: 10.12677/sa.2026.157161

reduce curtailment, and improve economic efficiency, with accurate wind speed prediction being the key to precise power forecasting. This paper devotes to a forecasting framework called Deep Ensemble Wind-Speed-Driven Physically-Conformal Power Forecasting Model, to obtain more accurate prediction of wind power. In the first stage, an ensemble of LSTM, TCN and Transformer models stacked by XGBoost is proposed to estimate the current wind speed. This design keeps wind-speed inputs continuous in time for multi-day rolling forecasts. Thereafter, a monotonic physical power curve relating wind speed to power is employed, with the addition of XGBoost-based residual learning. Then, the power prediction intervals of predefined confidence can be derived based on quantile regression and split conformal method. Experiments using actual wind farm data and comparative analyses have shown that this model effectively improves the accuracy of wind power prediction and ensures a more stable coverage probability. Moreover, the model can leverage this performance advantage to directly convert the prediction intervals into warning signals for rapid power ascent and descent. Therefore, it provides a physically consistent and engineering-usable output power prediction solution for the operation and maintenance decisions of the wind farm.

Keywords

Wind Power Forecasting, Deep Ensemble Wind-Speed-Driven Forecasting Model, Residual Learning, Split Conformal, Ramp-Down Warning

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

在新能源电力系统中, 风电机组的实际出力具有显著的随机性、间歇性与非平稳性。这些特性会在分钟级时间尺度上, 直接影响电力系统的调度计划制定、电力现货市场申报以及发电结算偏差管理等关键环节[1][2]。相关综述性研究等指出, 短期风电功率预测正逐步从单纯追求模型精度, 演变为覆盖业务流程与风险管控的一体化系统工程[3]。

本文的研究数据来源于甘肃省河西走廊某典型风电场的真实风电机组数据, 甘肃由于地处河西走廊狭管地形地带, 特殊的地形条件使该区域呈现出季节性强、极端风况频发等典型特征, 气流运动受地形阻隔与狭管效应影响明显[4], 导致风速分布不均、功率波动幅度大, 对短期功率预测模型的稳健性与适应性提出了更高要求。

风电功率预测的研究脉络可分为物理和统计的传统方法和深度时序模型等[5]。经典做法通常以理论功率曲线作为先验依据, 随后执行保序回归模型, 再通过插值方法获得直观预测结果[6]。面对长时间段历史数据输入与多时间尺度特征, 近年深度时序模型在通用时序预测基准测试中表现突出[7]。文献[8]提出的时序融合 Transformer (Temporal Fusion Transformer, TFT)模型, 融合门控循环单元、注意力机制与变量选择网络, 兼顾表达能力与一定可解释性, 已广泛应用于能源负荷、价格及气象等多步、多变量预测任务; 文献[9]设计的补丁时序卷积自注意力网络(Patch-based Temporal Self-Supervised Transformer, PatchTST)模型, 通过补丁化处理与通道独立自注意力结构建模, 确保较长期预测下的良好拟合能力; 文献[10]构建的时序网络(Times Network, TimesNet)模型, 将一维时间序列映射为含多周期成分的二维张量, 在兼顾长期趋势与季节性波动上具有优势; 文献[11]提出的分层时序聚合网络(Hierarchical Temporal Aggregation Network, N-HiTS)模型, 依托多分辨率分层残差叠加结构与多尺度插值设计, 通过逐级分解与重构, 提升长期预测下对趋势与季节性的刻画能力。

面向电力调度与市场交易的决策需求,预测区间的样本覆盖能力与可解释性至关重要。共形预测方法提供了不依赖数据分布假设的频率学性质;分割共形方法在高维回归任务中实现高效的覆盖保证;共形化分位回归进一步结合条件分位回归与分割共形,在适配异方差特性的同时,在给定覆盖目标下缩短区间长度[12]。这些误差估计方法,可与物理基线加残差学习的预测模型自然对接,其输出结果能够直接转化为工程决策所需的策略,为实际调度与交易决策提供直观且可靠的量化依据。

综上所述,现有研究在物理约束、残差学习和不确定性量化三个方向均取得了丰富成果,但在针对本研究所面向的风速驱动理论功率预测场景时仍存在若干空白。为此,本文提出深度集成风速预测驱动的物理约束与共形功率预测模型(DES-PCP 模型),该模型围绕先预测风速再推导功率、物理单调约束结合残差学习、分位预测搭配分割共形方法的核心设计原则,构建一个从风速与理论功率数据到调度和交易决策的一体化预测系统。该系统通过输出保底曲线、余量曲线和识别一小时内功率爬坡与骤降的变化方向,从而实现输出可直接执行的策略对象,为极端工况预警提供依据。

本文的主要贡献体现在三个方面。其一,提出一种统一物理先验、残差与分割共形的风电功率预测模型 DES-PCP。其二,面向实时风速 u_t 难以获取的场景,构建短期风速深度集成模型并结合堆叠策略。其三,在模型输出层面设计保底曲线、余量曲线以及爬坡骤降告警机制,将点预测与区间预测结果直接映射为电力交易与运行控制可用的决策量,并在 15 分钟时间分辨率与滚动回测的设置下,系统性对比多种近期代表性预测模型,展示出本文模型在 MAE、RMSE 与 R^2 等指标上的稳定优势。

2. DES-PCP 模型介绍

本文提出了 DES-PCP 模型,一种由深度集成风速预测驱动、同时结合物理约束与分割共形的风电功率预测方法。模型通过风速预测阶段提供稳健的当前风速估计,以单调物理功率曲线与残差学习构建物理一致的功率点预测,并生成具有覆盖保证的预测区间,进一步得到保底、余量曲线及爬坡骤降预警信号,从而在同一框架内同时解决功率预测精度、物理一致性与风险刻画三类问题。




Figure 1. Deep ensemble wind-speed-driven physically-conformal power forecasting model
图 1. 深度集成风速预测驱动的物理约束共形功率预测模型

DES-PCP 模型整体结构如图 1 所示,可概括为五个连续步骤。首先,对原始风速与机头风速法理论功率进行时间对齐、缺失填补和特征构建;其次,构建由 Transformer [13]、LSTM (Long Short-Term Memory) [14]和 TCN (Temporal Convolutional Network) [15]组成的风速深度集成模型,并通过 XGBoost [16]堆叠得到稳健的当前风速估计;第三,基于历史风速及预测风速和功率数据,通过分箱去噪与保序回归恢复单调物理功率曲线,结合插值以及先验条件,获得连续平滑的功率基线;第四,以理论功率与物理基线之差为目标,采用带单调约束的 XGBoost 残差模型拟合偏差分量,将学习到的残差叠加回基线,得到功率点预测;最后,利用分位数回归与分割共形方法对预测误差进行区间量化,并修正初始分位区间,形成具有覆盖保证的 P10、P90 预测区间,其下沿可视为保底曲线,上沿可视为余量曲线,再通过区间不相交规则识别未来一小时内的大幅爬坡和骤降事件,为备用配置和申报调整提供统一的决策接口。

2.1. 风速预测：深度集成与元学习器模型

风速预测阶段是 DES-PCP 模型的组件之一,能够为功率预测后端提供可靠的预测风速输入。本阶段采用深度集成与元学习器相结合的方法,通过三个具有互补归纳偏置的基学习器捕捉风速序列的模式特征,再使用 XGBoost 元学习器进行自适应融合,确保在各种风况下都能提供稳健的风速预测。

2.1.1. LSTM-TCN-Transformer 模型：基学习器

为在同一输入窗口下同时刻画风速序列的多尺度统计结构,本研究创新性地构建由 LSTM、TCN 与 Transformer 组成的并行异构基学习器集合,并通过统一的特征构建模块向三者提供一致的信息约束。

在并行建模阶段,三类基学习器面向不同的时间依赖机制:LSTM 通过门控记忆对隐状态与记忆单元进行递推更新,能够在较长时间跨度上保留风速的缓慢变化趋势,并对局地突发扰动形成一定平滑,从而更适合中长期背景与惯性成分的建模;TCN 基于一维扩张卷积实现多尺度感受野叠加,利用因果约束确保预测仅依赖历史信息,并通过残差结构稳定梯度传播,因而在较短路径上对高频波动与中短期周期结构具备更高的计算效率与表达能力;Transformer 则依靠多头自注意力在整段历史窗口内自适应分配权重,能够捕捉远距离相关性及相位变化、突变模式等非局地依赖。最终,三路分支分别输出对应的当前步风速预测,构成后续元学习融合的核心输入。

2.1.2. XGBoost 模型：元学习器

为自适应整合三类基学习器的互补优势,本研究采用 XGBoost 作为元学习器执行堆叠融合。元学习融合模块首先将三路点预测与上下文特征进行拼接,形成元特征向量 z_t ,随后由 XGBoost 学习从多视角预测到最终风速估计的非线性映射,训练阶段采用前向链式交叉验证构建元特征矩阵,输出当前步风速融合结果 $\hat{u}_t$ 。

2.2. 功率预测：物理引导的残差学习与误差量化

功率预测阶段是 DES-PCP 模型的核心组件,负责将风速预测阶段提供的风速序列转换为精确的功率预测及其可靠的误差区间。本阶段采用物理基线和数据驱动修正的混合建模思想,构建单调功率曲线,然后使用特征学习动态残差,最后通过分位数回归与共形预测相结合的方法实现区间预测。

2.2.1. 物理单调功率曲线的构建

物理功率曲线描述了风电机组的风速 - 功率转换关系。首先根据风电机组运行机制确定切入风速 u_{in} 和切出风速 u_{out} 。考虑到原始风速 - 功率数据包含大量测量噪声与异常波动,将风速区间划分为 K 个箱,对每个箱用风速均值和截尾均值构造代表点并按样本数加权。随后对代表点序列施加单调非减约束,采用保序回归,数学公式为

$$\tilde{f} = \arg \min_{f \in \mathcal{M}} \sum_{k=1}^K w_k (\bar{p}_k - f(\bar{u}_k))^2, \quad (1)$$

其中, $\mathcal{M} = \{f: f \text{ 分段常数或线性且单调非减}\}$ 。为减弱保序回归的阶梯伪影, 进一步使用埃尔米特插值 (PCHIP) 对结果进行平滑, 得到连续且保持单调性的曲线 $\tilde{f}_{\text{pchip}}$ 。最终物理功率曲线定义为

$$f(u) = \begin{cases} 0, & u < u_{\text{in}} \\ \tilde{f}_{\text{pchip}}(u), & u_{\text{in}} \leq u < u_{\text{out}} \\ 0, & u \geq u_{\text{out}} \end{cases} \quad (2)$$

该构造确保了功率曲线在切入前和切出后为零以及在有效工作区间内单调递增的合理性。

本文所构建的单调功率曲线, 并非采用厂家提供的标准理论曲线, 而是基于风电场历史运行数据拟合得到的场站经验曲线。两类曲线均刻画风速与功率的非线性关联, 且符合风机运行物理规律: 低风速下功率趋近于零, 中风速阶段功率随风速抬升, 高风速则受额定功率与切出风速限制。理论曲线体现机组理想设计特性, 经验曲线则依托实测数据, 可反映地形、局地风况及机组运行状态的综合影响。但经验曲线也存在局限, 其精度受样本数量、数据完整性制约, 异常测点、限电调度等问题会造成曲线偏差; 所用数据未纳入风向、空气密度、湍流强度等参数, 物理表征存在近似性; 同时该曲线仅表征历史统计规律, 场站环境或控制策略改变后, 需结合新数据重新校准。

2.2.2. 残差学习与点预测

仅依赖物理曲线难以覆盖尾流效应等时变因素影响, 为此模型引入残差学习进行动态修正。定义时刻 t 的残差为 $r_t = y_t - f(u_t)$, 其中 y_t 为理论功率的实际值。构建特征向量 x_t , 并采用 XGBoost 学习残差映射 $\hat{g}(x_t)$ 。为确保整体风速-功率关系保持物理先验, 对与风速直接相关的特征维度及其低阶滞后统计量施加单调递增约束。最终点预测由物理基线与残差修正共同给出:

$$\hat{y}_t = f(u_t) + \hat{g}(x_t). \quad (3)$$

2.2.3. 误差量化与区间预测

为获得可靠的不确定性区间, 本文将分位数回归与分割共形校准结合, 前者刻画条件异方差, 后者修正潜在系统偏差并提供有限样本覆盖保证。具体地, 对分位水平 $\tau \in \{\alpha/2, 0.5, 1-\alpha/2\}$ 分别训练三个分位数回归模型, 每个模型通过最小化 pinball 损失函数进行训练, 公式为

$$\mathcal{L}_\tau(g) = \sum_{t \in \mathcal{D}_t} \rho_\tau(r_t - g(x_t)), \quad (4)$$

其中, $\rho_\tau(e) = e \cdot (\tau - 1_{\{e < 0\}})$ 为分位数损失函数。得到上下功率分位数预测 $\hat{q}_{\alpha/2}(x_t)$ 与 $\hat{q}_{1-\alpha/2}(x_t)$ 。

考虑到分位数模型可能产生系统偏差, 进一步使用分割共形方法进行校准。将训练数据 $\mathcal{D}_{\text{train}}$ 划分为模型训练集 $\mathcal{D}_{\text{model}}$ 和校准集 $\mathcal{D}_{\text{cal}}$, 在训练集训练分位数回归模型后, 在校准集上计算非一致性分数 $s_i = \max\{\hat{q}_{\alpha/2}(i) - y_i, y_i - \hat{q}_{1-\alpha/2}(i), 0\}$, $i \in \mathcal{D}_{\text{cal}}$, 并取其经验 $(1-\alpha)$ 分位数 $\hat{q}_{\text{conf}}$ 作为校准常数。则对新样本 x_t 的共形预测区间为

$$[\hat{y}_t^{\text{lo}}, \hat{y}_t^{\text{hi}}] = [\hat{q}_{\alpha/2}(t) - \hat{q}_{\text{conf}}, \hat{q}_{1-\alpha/2}(t) + \hat{q}_{\text{conf}}]. \quad (5)$$

在训练集、校准集和测试集满足可交换性的假设下, 上述构造满足

$$\mathbb{P}\{Y_t \in [\hat{y}_t^{\text{lo}}, \hat{y}_t^{\text{hi}}]\} \geq 1 - \alpha, \quad (6)$$

从而在样本下提供有频率学保证的区间覆盖率[17]。

2.3. 基于预测区间的决策支持模块

DES-PCP 模型可以将预测转化为可直接用于运行决策的指标与预警信号，整体流程如图 2 所示。




Figure 2. One-hour ramp-up and ramp-down warning decision process based on prediction intervals

图 2. 基于预测区间的一小时爬坡与骤降预警决策流程

2.3.1. 区间到决策量的映射原理

基于功率预测阶段输出的点预测 $\hat{y}_t$ 和预测区间 $[\hat{y}_t^{lo}, \hat{y}_t^{hi}]$ ，我们定义三个核心决策量，分别是保底功率曲线 $F_t = \hat{y}_t^{lo}$ 、点预测功率 $M_t = \hat{y}_t$ 和备用功率曲线 $H_t = \hat{y}_t^{hi}$ 。对于置信水平 $1-\alpha$ ，有

$$P\{Y_t \in [F_t, H_t]\} \geq 1-\alpha, \quad (7)$$

其中，保底功率 F_t 指理论功率低于此值的概率不超过 $\alpha/2$ ，适合作为保守的发电计划值；备用功率 H_t 指

理论功率超过此值的概率不超过 $\alpha/2$ ，反映了潜在的发电潜力；点预测 M_t 指作为期望发电水平的参考。

2.3.2. 一小时爬坡骤降预警系统

短时间内功率急剧变化的爬坡和骤降事件对电网稳定性构成严重威胁[18]。基于预测区间，我们构建可提前一小时预警的爬坡骤降预警系统，爬坡骤降预警的触发条件基于预测区间的相对位置，即：

$$\begin{aligned} \text{上升预警: } \mathcal{A}_t^\uparrow &= \mathbf{1}F_{t+4} - H_t \geq \tau, \\ \text{下降预警: } \mathcal{A}_t^\downarrow &= \mathbf{1}H_{t+4} - F_t \leq -\tau, \end{aligned} \quad (8)$$

其中， $\tau > 0$ 是爬坡阈值。爬坡阈值 τ 确定为

$$\tau = Q_{1-\pi}(|Y_{t+4} - Y_t|), \quad (9)$$

其中， $Q_{1-\pi}$ 是历史一小时功率变化绝对值的 $1-\pi$ 分位数， π 是容忍的非重大爬坡比例。为避免瞬时波动导致的误报，模型引入持续性和迟滞机制。采用持续 K 步与上下行不同的阈值避免抖动。

3. 数据与实验设置

3.1. 数据集与预处理

本研究基于甘肃瓜州大梁地区真实风电场站 2022 年 11 月 1 日至 2025 年 7 月 31 日的数据，原始数据的时间分辨率为 5 分钟，并提取其中的机头风速法理论功率和风速数据。本文以机头风速法计算得到的理论功率作为预测目标变量。

3.1.1. 时间对齐与缺失值处理

我们首先将所有时间戳聚合到最邻近的 15 分钟整数倍时间格点 t_k 上，从而形成一个标准的等间隔时间序列。对于聚合到同一时间格点 t 的多个观测值，我们采用平均值作为该时刻的代表值。若某时间格点内无任何观测值，则将该时刻标记为缺失。对于被标记为缺失的观测，本文对风速 u_t 与理论功率 p_t^{theo} 统一采用分段线性插值恢复短时缺测段。经过此步骤，我们得到规整的等间隔序列 (u_t, p_t^{theo}) ，其中 u_t 为风速(m/s)， p_t^{theo} 为理论功率(MW)。

3.1.2. 特征构建

特征构建在完成 15 分钟等间隔重采样后进行。时间轴以固定窗口推进，任一时刻 t 的特征只由 t 及之前的观测历史信息得到，避免未来信息泄漏。

首先构建风速的滞后向量，用最近 $L = 24$ 个步长记录当前与过去的风速状态，为模型提供必要的短期记忆。并在该窗口内计算均值、标准差和极值等滚动统计量，以及一阶和多步差分，增强对快速抬升或回落的敏感性。时间周期性采用正余弦嵌入对日内 96 个时间段、周内 672 个时间段进行编码，为模型提供稳定的昼夜与周节律参考。为了更好地刻画季节性与长期结构，还为周内同一时间段记录历史中位数及其相对偏离，并按时间滚动更新。上述构件共同形成风速预测阶段的输入特征。

功率预测阶段的特征在风速预测阶段的基础上增加物理先验，以历史窗口拟合的单调功率曲线 $f(\hat{u})$ 作为确定性映射，将 $f(\hat{u}_t)$ 并入特征，并在树模型中对与风速直接相关的维度施加单调递增约束，确保风速 - 功率关系方向一致、符合物理先验。

3.2. 实验设置

3.2.1. DES-PCP 风速预测

DES-PCP 模型以甘肃瓜州大梁地区真实风电场的数据为输入，利用历史数据片段及其统计特征，构

建当前步风速的集成预测模型 $\hat{u}_t = \mathcal{F}(s_t)$ 。

风速预测阶段采用两层级集成结构，第一层由三类深度基学习器构成，分别是 Transformer、LSTM 与 TCN，并行接收历史片段 s_t 及其特征，预测当前风速 u_t ，三者均采用均方误差损失和自适应优化器训练。第二层为元学习器 XGBoost，通过基于时间顺序的堆叠策略，将 Transformer、LSTM 与 TCN 三路基学习器输出与滚动统计、时间编码等上下文特征融合为最终风速估计 $\hat{u}_t$ 。

3.2.2. DES-PCP 功率预测阶段实现

DES-PCP 的功率预测阶段由三部分顺序衔接。第一步，输入风速预测阶段得到的风速估计 $\hat{u}$ ，在历史窗口上利用风速 - 功率观测得到单调的物理功率曲线 $f(\hat{u})$ 。物理曲线仅在风速处于 3~24 m/s 的有效工作区间内进行拟合。在该区间内将风速等距划分为约 80 个分段，对每个分段计算归一化功率均值以抑制噪声，再采用保序回归得到非降映射，并在致密风速网格上应用 PCHIP 进行平滑插值，从而构造出连续且单调的风速 - 功率基线函数。

第二步，在训练窗口上构造理论功率的残差序列，并在有效物理区间内用 XGBoost 模型进行学习，并按时间顺序将剩余样本划分为前 80% 的训练集和后 20% 的校准集。残差模型采用平方损失的 XGBoost 回归器，并配合 L_2 正则化控制模型复杂度。最终，点预测通过物理基线结合残差的方式得到。

第三步，为获得覆盖水平 $1 - \alpha = 0.9$ 的误差区间，采用分位数学习联合分割共形的混合方案。在下分位、中位数、上分位三个水平上训练分位数回归器，得到未校准的上下沿；随后用训练窗口末端的独立校准子集计算非一致性分数，取目标分位得到一个标量校准余量，分别向下和向上扩张上下沿，最后形成经校准的区间。

3.2.3. 分箱数设置与敏感性分析

在经验功率曲线构建过程中，风速分箱数 K 会影响分箱均值的平滑程度和局部表达能力。为考察该超参数对模型结果的影响，本文在仅改变物理基线构建阶段的分箱数 K 的条件下，采用单起点七日预测窗口进行敏感性分析。结果如表 1 所示。

Table 1. Influence of bin number K on DES-PCP forecasting performance

表 1. 分箱数 K 对 DES-PCP 模型预测性能的影响

K	MAE	RMSE	R^2	COV ₉₀
20	3.086	5.088	0.972	0.892
60	3.118	5.137	0.971	0.895
80	3.113	5.188	0.971	0.900
120	3.287	5.261	0.970	0.879
160	3.228	5.395	0.968	0.895

从表 1 可以看出，当 K 在 20 至 80 范围内变化时，DES-PCP 模型的 MAE、RMSE 和 R^2 波动较小，说明模型对经验功率曲线分箱数具有一定鲁棒性。当 K 进一步增大至 120 或 160 后，误差指标有所上升，表明过细分箱可能使曲线更容易受到局部噪声和样本稀疏的影响。综合多个指标，本文采用 $K = 80$ 作为经验功率曲线构建的默认分箱数。该设置下与目标覆盖率 0.90 接近，同时 MAE 和 RMSE 与其他较优设置差异较小，能够在曲线平滑性、局部表达能力和区间可靠性之间取得较稳健的平衡。

3.2.4. 评价指标

本节评估严格使用历史数据集，将每日 00:00 作为时间分割点，执行滚动预测流程。采用 15 分钟采

样频率，训练集选用测试集起点前的全部理论功率和风速数据，测试集起点设定为 2025 年 6 月 30 日。实验设定切入风速 $u_{in} = 3 \text{ m/s}$ 、切出风速 $u_{out} = 24 \text{ m/s}$ 。实验统一在测试窗口内计算 MAE (平均绝对误差)、RMSE (均方根误差)、WAPE (加权平均百分比误差)、sMAPE (对称平均绝对百分比误差)、 R^2 (决定系数)五个核心指标与两个区间指标。核心指标的计算公式分别为

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (10)$$

$$\text{RMSE} = \left(\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \right)^{1/2} \quad (11)$$

$$\text{WAPE} = \frac{\sum |y_i - \hat{y}_i|}{\sum |y_i| + \varepsilon} \times 100\% \quad (12)$$

$$\text{sMAPE} = \frac{2}{N} \sum \frac{|y_i - \hat{y}_i|}{|y_i| + |\hat{y}_i| + \varepsilon} \times 100\% \quad (13)$$

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2 + \varepsilon} \quad (14)$$

两个区间指标分别为区间覆盖度 COV_{90} 和平均带宽 INTW。区间覆盖度 COV_{90} 为实际值落入 $[lo_i, hi_i]$ 区间的比例；平均带宽 INTW 计算公式为

$$\text{INTW} = \frac{1}{N} \sum (hi_i - lo_i). \quad (15)$$

3.3. 实验结果

本节从两方面对 DES-PCP 模型的性能进行评估：一是固定起点、不同预测时间下的功率点预测与区间预测表现，二是基于预测区间的一小时爬坡骤降预警能力。

3.3.1. DES-PCP 模型不同时间步预测结果

为评价模型的跨日稳健性，固定起点为 2025 年 6 月 30 日，实验共测试了 DES-PCP 模型在一天、三天、七天、十天的出力预测结果，具体结果如下表 2 所示。


Table 2. Evaluation metrics of DES-PCP for different forecasting horizons

表 2. DES-PCP 模型不同预测天数评价指标


时间	MAE	RMSE	WAPE (%)	sMAPE (%)	R^2
一天	1.415	2.083	16.05	18.24	0.873
三天	2.874	5.024	15.24	18.04	0.915
七天	2.274	5.928	19.40	18.52	0.879
十天	2.414	5.916	17.08	18.69	0.923

实验还针对出力的实际值和 DES-PCP 模型的预测值进行可视化，其中实线为理论功率实际值，虚线为预测值，并绘制了误差区间。DES-PCP 模型一天、三天、七天、十天的滚动预测效果图如图 3 所示。


从单日预测结果来看，MAE 约为 1.415 MW，说明在 15 分钟分辨率下的平均绝对偏差较小，能够满足调度侧对短期点状误差控制的要求；RMSE 与 MAE 数值接近，表明大误差样本占比较低，整体预测较为稳定。区间预测方面，覆盖率高于目标 90%，说明区间略偏保守。




(a) 一天



(b) 三天



(c) 七天



(d) 十天

Figure 3. Prediction performance of DES-PCP under different forecast horizons**图 3.** DES-PCP 模型在不同预测步长下的性能表现

从多日预测结果来看, MAE 在 3~10 天区间内稳定在 2.27~2.874 MW 左右; RMSE 的整体波动较小, 始终维持在 5 到 6 MW 范围内。在相对误差指标上, WAPE 约为 15%~19%, sMAPE 基本稳定在 18% 左右, 10 天预测的 WAPE 略有下降。就不确定性与成本平衡而言, 多日滚动预测的区间覆盖率在 3~10 天内保持约 90%, 说明分割共形方法在跨日场景下依然能够提供可靠的有限样本覆盖保证。

3.3.2. 一小时爬坡骤降预警结果

本节评估基于预测区间的一小时爬坡和骤降预警模块在 2025 年 7 月 15 日至 2025 年 7 月 22 日七天窗口上的表现。预警算法仅依赖模型给出的 90% 功率预测区间, 通过对未来一小时区间下界与当前区间上界的组合进行比较, 实现对大幅上升和下降事件的提前识别, 并通过持续性与迟滞机制抑制瞬时波动带来的虚假预警。我们将理论功率的实际值曲线、点预测、预测上下界以及自动识别出的上升和下降预警时段统一绘制在图中, 如图 4 所示。




Figure 4. DES-PCP model continuous rolling warning results for one week
图 4. DES-PCP 模型一周连续滚动预警结果

图 4 中实线表示模型点预测, 长虚线与短虚线分别给出上界和下界, 从图 4 可以看到大部分时间段内理论功率均被 90% 区间有效包络, 尤其是在大幅波动阶段, 区间宽度随不确定性增加而自适应放大, 为后续预警判定提供了可信依据。

半透明竖带对应一小时上升预警和下降预警区间。可以观察到, 七天窗口内能够识别出的主要大爬坡和骤降事件都能够被预警带覆盖, 未对仅有轻微波动的平缓段给出预警, 说明模型成功过滤了大量幅度有限、对系统冲击较小的变化, 实现了利用区间估计提前锁定未来爬坡骤降事件的目标。

为进一步客观评估爬坡骤降预警模块, 本文在 2025 年 7 月 1 日至 2025 年 7 月 31 日连续滚动窗口上计算 Precision、Recall 和 F1 分数。不同阈值下的结果如表 3 所示。

Table 3. Event-level evaluation results under different warning thresholds
表 3. 不同预警阈值下的事件级评价结果

阈值	预测事件数	TP	FP	FN	Precision	Recall	F1
0.6τ	78	64	14	1	0.821	0.984	0.895
0.8τ	67	59	8	6	0.881	0.908	0.894
1.0τ	61	54	7	11	0.885	0.831	0.857
2.0τ	44	42	2	23	0.954	0.646	0.771
4.0τ	16	16	0	49	1.000	0.246	0.395

从表 3 可以看出, 预警阈值 τ 控制了误报与漏报之间的权衡。当阈值降低至 0.6τ 或 0.8τ 时, 模型召

回率显著提高，说明较低阈值有利于减少漏报；但与此同时，误报数量也有所增加。当阈值提高至 2.0τ 以上时，模型预警行为更加保守，但 Recall 明显下降。综合来看，默认阈值 1.0τ 保持了较高精确率和较低误报水平，适合作为本文主模型的稳健预警设置。

综合以上分析，基于预测区间的爬坡和骤降预警模块不仅能够有效识别爬坡骤降事件，而且取得了较高的 Precision、Recall 和 F1 分数，说明该模块具备较好的预警准确性与实用性。不同阈值下的结果进一步表明，预警阈值 τ 可根据实际业务需求在减少漏报和降低误报之间进行调节。该预警机制能够为风电场滚动调度、备用配置和运行风险管理提供具有工程可操作性的决策支撑。

4. 对比实验

4.1. 对比实验设计

为全面评估 DES-PCP 模型的性能，我们将其与四类具有代表性的深度时序模型进行系统性对比，包括 PatchTST、TimesNet、TFT 以及 N-HiTS 模型。这些模型涵盖了当前深度时序预测的主要技术路线。表 4 中具体阐述了每种对比模型的架构以及模型优势。

Table 4. Modeling methods and advantages analysis of various comparison models
表 4. 各类对比模型建模方式与优势分析

模型	建模方式
PatchTST	将长序列切成 patch，用 Transformer 在时间维上建模。
TimesNet	把序列转成二维时间周期表示，用卷积提取周期特征。
TFT	门控 RNN + 注意力 + 变量选择的多步预测框架。
N-HiTS	分层残差结构，在不同时间尺度上分解和重构序列。

对比实验采用 15 分钟分辨率的瓜州大梁典型风电场的风电数据，以 2025 年 6 月 30 日 00:00 作为训练和测试的截断时间点 t_0 ，实验设置与第四节相同，所有模型共享相同的数据预处理流程，确保比较基准的一致性。

4.2. 对比实验结果分析

2025 年 6 月 30 日瓜州大梁风电场出力预测单日的对比实验结果如表 5 及图 5 所示。表 5 展示了对比模型功率预测结果评价指标，图 5 对预测结果进行可视化，定量和定性地评估 DES-PCP 相对于四个深度时序预测对比模型的性能差异。

Table 5. Evaluation metrics for power forecasting results of each comparison model
表 5. 各对比模型功率预测结果评价指标

模型	MAE	RMSE	WAPE	sMAPE	R^2
PatchTST	3.324	4.288	37.71	59.22	0.464
TimesNet	4.089	5.194	46.39	56.39	0.213
TFT	3.319	4.256	37.65	48.98	0.472
N-HiTS	2.805	3.839	31.82	46.00	0.570
DES-PCP	1.415	2.083	16.05	18.24	0.873

从表 5 可以看出，在所有误差类和相关性指标上，DES-PCP 均明显优于四个深度时序模型。就绝对误差而言，DES-PCP 的 MAE 为 1.415 MW，RMSE 为 2.083 MW，分别远低于另外四个对比模型。以综

合表现最好的模型 N-HITS 为参照, DES-PCP 在 MAE 上相对降低约 49.6%, 在 RMSE 上降低约 45.7%, 说明该方法在整体误差控制和极值偏差抑制方面都具有优势。相对误差指标方面, DES-PCP 的 WAPE 和 sMAPE 分别为 16.05% 和 18.24%, 表明新方法对不同功率水平段均具有更好的相对精度。相关性指标 R^2 方面, DES-PCP 达到 0.873, 高于其他模型。这意味着 DES-PCP 模型对风功率时序结构的拟合能力更强。




Figure 5. Curves of model power forecasting results for each comparison model

图 5. 各对比模型功率预测结果曲线

图 5 从可视化的时序曲线层面进一步佐证了上述结论。阴影为理论功率的实际值, 折线为不同模型的预测结果。可以观察到, DES-PCP 在功率快速爬坡和回落阶段能够较好地跟踪上升幅度与拐点位置, 峰谷高度与实际观测更加接近; 相比之下, TimesNet 在多个峰值段存在低估, PatchTST 与 TFT 在爬坡初期响应偏慢且谷值附近偏高, N-HITS 虽整体形状较好, 但在高频波动和局部尖峰处存在明显平滑化倾向。通过物理单调曲线与残差学习的叠加, DES-PCP 在抑制噪声的同时保留了更多真实的高频动态。

为考察模型在不同起点和时段上的稳健性, 本文在 2025 年 6 月到 7 月选取多组代表性起点, 采用相同设置进行重复滚动评估。结果显示, 在所有起点上 DES-PCP 的误差指标均不劣于最优基线模型, 在多数起点上实现了不同程度的改进, 且跨起点的性能波动较小, 其指标水平整体保持在表 5 所示预测结果的同一数量级, 说明所提出方法在多日滚动预测任务中具有较好的时间稳健性。

综合表 5 的量化指标和图 5 的可视化图像可以看出, 本文提出的模型不仅显著提升了整体和相对误差指标, 还提高了日内预测的可靠性与可解释性。相比纯黑箱深度模型, DES-PCP 的结构更便于调度和运维人员理解与诊断, 在复杂风况下能够提供精细的功率预测, 为后续爬坡骤降预警奠定了模型基础。

5. 消融实验

5.1. 消融实验设计

为深入解析 DES-PCP 模型中各组件的贡献, 本节通过系统的消融实验, 在控制变量的原则下评估各关键模块对最终功率点预测性能的影响。消融实验的测试起点为 2025 年 7 月 10 日, 其他实验设置与第 4 节保持完全一致。完整 DES-PCP 的点预测为物理基线 $f(\hat{u}_t)$ 与残差模型 $g(\cdot)$ 之和。基于此, 我们构造了以下四个消融变体:

- (1) 无残差修正变体: 该变体完全移除数据驱动的残差修正模块, 仅保留物理功率曲线, 即:

$$\hat{y}_t^{\text{w/o Residual}} = f(\hat{u}_t). \quad (16)$$

- (2) 无单调约束变体: 该变体移除 XGBoost 中的单调性约束, 对应表达式为

$$\hat{y}_t^{w/o \text{ Mono}} = f(\hat{u}_t) + \hat{g}_{\text{uncon}}(\mathbf{x}_t),$$

(17)

其中， $\hat{g}_{\text{uncon}}$ 与完整模型共享相同的特征集和超参数配置。

(3) 线性残差模型变体：该变体将非线性树模型替换为带 L_2 正则化的线性回归，可以得到

$$\hat{g}_{\text{ridge}} = \arg \min_{\beta} \sum_{t \in D_{\text{tr}}} (r_t - \mathbf{x}_t^T \beta)^2 + \lambda \|\beta\|_2^2,$$

(18)

其中， $r_t = y_t - f(\hat{u}_t)$ 。此变体用于评估线性模型对复杂非线性残差模式的刻画能力。

(4) 无 PCHIP 平滑变体：该变体移除物理功率曲线中的 PCHIP 平滑步骤，仅使用保序回归得到的分段常数函数，即：

$$\hat{y}_t^{w/o \text{ PCHIP}} = f_{\text{iso}}(\hat{u}_t) + \hat{g}(\mathbf{x}_t).$$

(19)

实验中 XGBoost 配置保持一致，并在测试集上采用 MAE、RMSE、WAPE、sMAPE、 R^2 五个核心指标进行定量评估。

5.2. 消融实验结果分析

表 6 的消融实验以 2025 年 7 月 10 日为预测起点。图 6 为消融实验功率预测结果曲线，从表 6 及图 6 中可以看出，完整 DES-PCP 模型取得最优性能。

Table 6. Evaluation metrics for power forecasting results of ablation experiments
表 6. 消融实验功率预测结果评价指标

变体	MAE	RMSE	WAPE	sMAPE	R^2
DES-PCP	2.990	4.222	11.31	13.48	0.926
无残差修正变体	4.030	5.450	15.25	17.49	0.876
无单调约束变体	3.124	4.467	11.82	14.10	0.917
线性残差模型变体	3.701	5.018	14.00	15.89	0.895
无 PCHIP 平滑变体	4.025	5.445	15.23	17.47	0.876




Figure 6. Curves of power prediction results for ablation experiments
图 6. 消融实验功率预测结果曲线

各消融变体相对于完整模型的性能劣化呈现出清晰的层次结构。无残差修正的性能下降最大，MAE、RMS 和 WAPE、sMAPE 均上升约 30%左右，决定系数下降约 0.05。这一结果明确表明，仅依赖物理功

率曲线虽能捕捉宏观的风速-功率关系,但无法适应实际运行中的时变偏差。线性残差模型的 MAE 和 RMSE 亦上升约 20%,说明风速滞后、滚动统计和时间特征之间存在复杂非线性依赖。无单调约束的性能下降幅度相对较小,MAE 与 RMSE 上升约 5%,但依然表明单调约束在抑制局部反物理预测、降低方差方面具有积极作用。无 PCHIP 平滑的变体在 MAE、RMSE 和 R^2 上的退化程度接近无残差修正,说明几何粗糙的物理基线会迫使残差学习器耗费大量容量去纠正量化噪声,降低整体参数效率。

综合以上分析,以平滑单调的物理功率曲线作为基线,叠加具有足够表达能力的非线性残差学习器,并在关键物理特征上施加适度单调约束,再结合后续的误差区间校准,可在点预测精度、物理一致性与运行稳健性之间取得良好平衡,为进一步扩展误差区间量化和调度决策功能提供坚实基础。

6. 结论

本文围绕风速驱动的物理约束与共形功率预测模型 DES-PCP,系统地构建了从点预测、区间预测到一小时爬坡和骤降预警的完整技术路线,并在真实风电场数据上开展了多层次的实验评估。总体来看,DES-PCP 模型在预测精度、区间可靠性以及工程可解释性等方面均优于多种深度时序模型。

在点预测层面,针对单日滚动与多日单起点两类典型业务场景,DES-PCP 在 15 分钟分辨率下的 MAE 约为 1.415 MW,多日滚动预测下,MAE 稳定在 2.27~2.87 MW 范围, RMSE 始终控制在 5~6 MW 之间,相对误差指标 WAPE 基本维持在 15%~19%,sMAPE 约为 18%,能够满足调度侧对短期及中期风电功率预测精度的工程需求。与 PatchTST、TimesNet、TFT 与 N-HITS 等代表性深度时序模型的对比结果进一步表明,DES-PCP 在 MAE 和 RMSE 上分别实现了接近 50%的误差降幅, R^2 提升至 0.873,高于所有对比模型,说明该方法在刻画风功率随时间演化的结构性特征方面具有更强的综合能力。

在不确定性量化方面,基于分割共形构造的功率预测区间覆盖率接近目标 90%,单日略偏保守,多日保持稳定。区间宽度能够随功率波动程度自适应收缩或放宽,物理单调功率曲线提供合理边界,残差学习器修正系统性偏差和扰动,最终实现高覆盖率和合理区间宽度的平衡。

在风险预警层面,本文进一步利用预测区间构建一小时爬坡和骤降预警模块。该模块能够提前识别大幅功率变化事件,并结合持续性与迟滞机制降低瞬时波动带来的虚假预警。连续运行结果和事件级评价表明,该预警模块能够较准确地识别主要爬坡和骤降事件,并在 Precision、Recall 和 F1 指标上取得较好表现,为备用容量配置和滚动出清提供了可直接使用的量化风险信号。

消融实验进一步验证了各模块对整体性能的必要性。结果表明,去除残差学习或将其简化为线性模型都会显著降低精度,表明风速滞后、滚动统计与时间特征之间存在复杂非线性关系;取消单调约束或 PCHIP 平滑会导致基线功率曲线出现局部不连续,削弱极端工况下的稳健性。DES-PCP 结构在点预测、区间预测和预警性能上均表现最佳。这些结果验证了完整 DES-PCP 模型的架构设计是合理且必要的。

综上,DES-PCP 在真实风电场上的实验结果表明,将深度集成的风速预测、物理单调功率曲线、非线性残差提升与共形区间校准有机融合,能够在点预测精度、区间可靠性、爬坡骤降风险识别以及工程可解释性之间取得良好平衡。该模型一方面提升了风电功率短期和中期预测的精度与稳定性,另一方面通过一小时爬坡和骤降预警模块,为电网侧提供了可以直接对接调度与备用决策的量化风险指标。总体来看,DES-PCP 在实现风速驱动、物理约束与不确定性量化的一体化建模提供了一条可行而具有推广价值的技术路径,可为电力系统运行与电力市场交易中的风险管控与辅助决策提供有力支撑。

参考文献

- [1] 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.
- [2] 唐新姿,吴新波,郑勇,等. 风电功率短期预测技术研究进展[J]. 机械工程学报, 2022, 58(12): 213-227.

-
- [3] 李特, 黄孜滢. 机器学习在风力发电功率预测中应用综述[J]. 山东电力技术, 2025, 52(8): 45-55.
- [4] 董安祥, 胡文超, 张宇, 等. 河西走廊特殊地形与大风的关系探讨[J]. 冰川冻土, 2014, 36(2): 347-351.
- [5] 张智浩, 王聪, 张宏立, 等. 时间生成对抗网络样本扩增下的风电功率预测[J]. 电力系统及其自动化学报, 2025, 37(10): 64-74.
- [6] 沈小军, 付雪姣. 基于改进光滑样条的风电机组功率曲线建模方法[J]. 高电压技术, 2020, 46(7): 2418-2424.
- [7] 潘志松, 韩笑, 黎维. 基于深度学习的时间序列预测方法综述[J]. 南京航空航天大学学报, 2025, 57(5): 799-821.
- [8] Lim, B., Arık, S.Ö., Loeff, N. and Pfister, T. (2021) Temporal Fusion Transformers for Interpretable Multi-Horizon Time Series Forecasting. *International Journal of Forecasting*, **37**, 1748-1764.
<https://doi.org/10.1016/j.ijforecast.2021.03.012>
- [9] 刘新宇, 潘宇, 王亚辉, 等. 增强的超短期风电功率预测: 一种 PatchTST-POA-VMD-iTransformer 混合模型[J]. 电力系统保护与控制, 2025, 53(19): 68-78.
- [10] 段沁宇, 薛贵军, 谭全伟, 等. 基于 SVM 的改进 BWO-TimesNet 短期热负荷预测模型[J]. 广西师范大学学报(自然科学版), 2024, 42(6): 101-116.
- [11] 李楠, 刘佳佳, 赖心怡, 等. 基于时间序列神经分层插值模型的光伏功率超短期多步预测[J]. 智慧电力, 2024, 52(4): 69-77.
- [12] 金璋, 王学钦. 共型预测方法的发展和应用[J]. 中国科学: 数学, 2024, 54(12): 2121-2140.
- [13] Bentsen, L.Ø., Warakagoda, N.D., Stenbro, R. and Engelstad, P. (2023) Spatio-Temporal Wind Speed Forecasting Using Graph Networks and Novel Transformer Architectures. *Applied Energy*, **333**, Article ID: 120565.
<https://doi.org/10.1016/j.apenergy.2022.120565>
- [14] Hochreiter, S. and Schmidhuber, J. (1997) Long Short-Term Memory. *Neural Computation*, **9**, 1735-1780.
<https://doi.org/10.1162/neco.1997.9.8.1735>
- [15] Li, D., Jiang, F., Chen, M. and Qian, T. (2022) Multi-Step-Ahead Wind Speed Forecasting Based on a Hybrid Decomposition Method and Temporal Convolutional Networks. *Energy*, **238**, Article ID: 121981.
<https://doi.org/10.1016/j.energy.2021.121981>
- [16] Zheng, H. and Wu, Y. (2019) A XGBoost Model with Weather Similarity Analysis and Feature Engineering for Short-Term Wind Power Forecasting. *Applied Sciences*, **9**, Article 3019. <https://doi.org/10.3390/app9153019>
- [17] Guan, L. (2023) Localized Conformal Prediction: A Generalized Inference Framework for Conformal Prediction. *Biometrika*, **110**, 33-50. <https://doi.org/10.1093/biomet/asac040>
- [18] 张东英, 代悦, 张旭, 等. 风电爬坡事件研究综述及展望[J]. 电网技术, 2018, 42(6): 1783-1792.