

doi:10.3969/j.issn.1001-4616.2026.02.011

基于多元周期性网格与云模型混合通道的 功率预测研究

刘志仁¹, 杜云龙², 颜全椿³, 柴 贇², 曹卫青³, 杨勤胜³

(1. 国网江苏省电力有限公司无锡供电分公司, 江苏 无锡 214000)

(2. 国网江苏省电力有限公司, 江苏 南京 210098)

(3. 江苏方天电力技术有限公司, 江苏 南京 211000)

[摘要] 随着新能源发电技术的广泛普及, 功率预测已成为该领域不可或缺的研究方向。然而, 传统预测方法在面对不同时间尺度及多元因素影响时, 其新能源功率预测模型的动态性能表现出明显局限性, 致使预测精度难以达到理想水平。针对该问题本研究提出一种结合多元周期性网格与云模型混合通道的功率预测技术研究, 通过卡尔曼滤波器更新多元周期性网格, 使其能实时适应复杂环境变化, 精准捕捉时空动态特征, 实现周期特征动态优化。同时, 利用云模型混合通道的隶属度函数与概率修正优化, 融合多尺度信息并动态调整。仿真结果表明, 该方法有效提升了新能源功率预测在不同时空尺度下的准确性与稳定性, 为新能源领域功率预测提供了更有效的解决方案。在光伏功率预测中具有显著的推广意义, 为电力系统调度优化、负荷管理和智能化控制提供有力支持, 对促进光伏电站稳定运行和推动绿色能源发展具有重要的应用价值。

[关键词] 新能源功率预测, 多元周期性网格, 卡尔曼滤波器, 云模型混合通道

[中图分类号] O643/X703 [文献标志码] A [文章编号] 1001-4616(2026)02-0110-10

A Study of Power Prediction Based on a Hybrid Channel of Multivariate Periodic Grids and Cloud Models

Liu Zhiren², Du Yunlong¹, Yan Quanchun³, Chai Yun¹, Cao Weiqing³, Yang Qinsheng³

(1. State Grid Jiangsu Electric Power Co., Ltd. Wuxi Power Supply Branch, Wuxi 214000, China)

(2. Jiangsu Electric Power Co., Ltd., Nanjing 210098, China)

(3. Jiangsu Frontier Power Technology Co., Ltd., Nanjing 211000, China)

Abstract: In the wake of the extensive dissemination and application of new energy generation technologies, power prediction has emerged as an essential research area within this domain. Nevertheless, conventional prediction methodologies exhibit conspicuous limitations in the dynamic capabilities of new energy power prediction models when confronted with diverse time scales and the impacts of multiple factors, thereby rendering the attainment of desired prediction accuracy a challenging feat. In response to this predicament, the present study proposes an innovative power prediction technique that amalgamates the multivariate periodic grid with the cloud model hybrid channel. Through the utilization of the Kalman filter, the multivariate periodic grid is continuously updated in real-time, enabling it to adeptly adapt to complex and fluctuating environmental conditions, precisely capture spatio-temporal dynamic characteristics, and effectuate the dynamic optimization of periodic features. Concurrently, the cloud model hybrid channel is enhanced by leveraging the membership function with probability correction to seamlessly integrate multi-scale information and effectuate dynamic adjustments. Simulation outcomes convincingly demonstrate that this method significantly augments the accuracy and stability of new energy power prediction across varying spatio-temporal scales, thereby proffering a more efficacious solution for power prediction within the new energy realm. This approach significantly enhances photovoltaic power forecasting, supporting power system dispatch optimization, load management, and intelligent control, while promoting the stable operation of photovoltaic plants and advancing green energy development.

Key words: new energy power prediction, multivariate periodic grids, Kalman filter, cloud model hybrid channel

收稿日期: 2025-08-14.

基金项目: 国网江苏省电力有限公司科技项目资助项目(J2023116).

通讯作者: 颜全椿, 博士研究生, 高级工程师, 研究方向: 新能源及储能数智应用. E-mail: yanquanchun@126.com

“碳达峰”与“碳中和”是当今世界各国的共识,也是当今世界各国共同努力的方向^[1-2].在此背景下,以新能源为主的新能源发电将成为未来替代化石能源的重要方式,光电及风能电站的建造规模也大幅增加.但是,以光伏、风电等新能源为电网注入“绿色”能量的同时,其输出的波动性和不确定性也对电网的稳定可靠运行提出了新的要求^[3-4].因此,开展新能源发电功率预测方法的研究,具有重要的现实意义.

目前,国内外传统的物理建模法^[5-6]、统计方法^[7-8]和时间序列分析法^[9-11]等在面对复杂时空变化和多元因素时存在一定局限,特别是在系统参数变化和外部环境波动的影响下,预测精度难以满足新能源发电的需求.与此同时,人工智能方法,如神经网络^[12-13]、支持向量机(support vector machine, SVM)^[14-15]和随机森林^[16-17],虽然具有较强的适应能力,但在处理数据特征提取不足和多尺度信息融合等问题时仍面临挑战.为了解决这些问题,本文提出了一种结合多元周期性网格和云模型混合通道的创新方法,旨在提高光伏功率预测的精度与适应性.

虽然上述方法对于解决非线性、不确定性问题提供了有利条件,但是其预测精度存在一定瓶颈,且在多元、多维度情况下,对于数据的处理和功率预测动态分量优化方面还有所欠缺.文献[18]通过处理风电和光伏发电中的周期性变化、捕捉多维度、多通道信息,虽有效地提升了预测的稳定性,但捕捉精确的周期性特征可能需要非常精细的建模和调参,存在一定的挑战.文献[19]在获取周期性特征的基础上,结合了网格化的方式,在数据处理方面得到了显著的提升,但当网格规模变大时,其学习与推理的速度将会大幅度提高.文献[20]在网格建模的基础上,以残差网络为模型对数据进行训练,虽然提高了预测曲线与实际曲线的拟合度,但当样本数量较少时,深度网络极易出现“过拟合”现象,导致泛化能力不足.上述文献涉及到的方法,尽管在提升功率预测精度方面都有很大的进展,但都未充分考虑如何在更复杂、多变的环境条件下动态调整预测模型来适应不同时间尺度和多元因素的影响.

在许多应用场景中,环境数据是动态变化的,且变化具有时序性,这对预测模型动态性能有着较高要求.为了解决这个问题,本文提出了一种结合周期性网格与云模型多通道数据融合的创新思路.该方法通过建立多元周期性网格,引入卡尔曼滤波器,实现网格动态滚动,通过不断更新其状态来保持对环境变化的敏感性,将网格输出的功率和权重系数矩阵作为基本参数输入到云模型混合通道中,进一步校正预测结果,从而提升新能源功率预测的精度和适应性.本文所研究的光伏系统基于城市建筑屋顶分布式光伏发电场景,结合实际用户侧数据,具有强烈的周期扰动特性和环境耦合特征,适用于社区型光伏负荷管理与预测控制场景.

1 多元周期性网格建模

1.1 多元周期性网格分化技术

1.1.1 数据来源与领域划分

新能源功率预测的准确性依赖于对影响功率输出的多维特征的全面理解和有效融合.这些特征通常包括时间信息、气象参数和历史功率数据.然而,单一特征或维度的分析无法充分反映光伏功率的复杂变化规律.因此,通过构建多元周期性网格,可以实现对时间特征、气象特征和功率特征的多维度整合,为后续建模提供更加全面和精准的数据基础.多元周期性网格的构建不仅能有效捕捉功率的动态变化趋势,还能为特征提取、周期规律分析以及模型预测提供多维数据支持.这种数据结构能体现特征之间的时空关联性,为构建精准的功率预测模型奠定坚实基础.多元周期性网格建模流程图1所示.

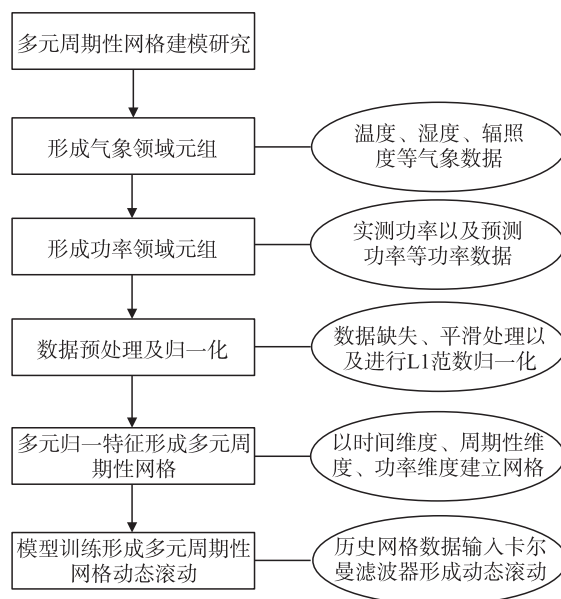


图1 多元周期性网格建模流程图

Fig. 1 Flow chart of multivariate periodic mesh modeling

1.1.2 数据预处理及网格构建

将上述气象数据、功率数据与时间构建成一一对应的高维数组,定义为 (t, W, P) 用于反映功率预测相关的多种数据来源与特征.

(1)时间特征 t 表示时间信息,是数据元组的时间维度,记录了功率及气象参数的时间戳. 时间特征主要包括实际采集时刻的时间标记以及未来预测时刻. 时间特征可进一步转化为周期性变量(如小时、日、周、季节),以捕捉功率随时间变化的规律.

(2) $W = \{w_1, w_2, \dots, w_n\}$ 表示气象特征的多维向量,是影响功率输出的关键变量,包括以下信息:

温度数据:单位为摄氏度($^{\circ}\text{C}$),记作 $Temp$;

湿度数据:单位为相对湿度(RH),记作 H ;

辐照度数据:单位为瓦特每平方米(W/m^2),记作 I_r ;

(3)功率特征 P 表示功率特征,包含历史功率信息及预测功率值. 历史功率值表示过去时刻的实际输出功率,用于构建趋势特征和预测模型输入. 通过简单规则或基准模型计算的功率预测值获得初步预测功率值,为后续网格动态调整提供初始参考.

在相同的尺度下对数据元组进行缩放,可以提高模型学习的稳定性和收敛性. 在多元周期性网格数据中,通常对每个特征的值进行归一化,以便它们具有相似的尺度. 在得到经上节处理过的数据元组后,采用 $L1$ 范数归一化对上述数据元组中的各个特征进行处理,形成归一化后的多元数据集, $L1$ 范数归一化计算公式为:

$$x'_{ij} = \frac{|x_{ij}|}{\|x_i\|_1}, \tag{1}$$

式中: x_{ij} :第 i 个数据元组中的第 j 个特征值; $\|x_i\|_1$:第 i 个数据元组的 $L1$ 范数; x'_{ij} :第 i 个数据元组中第 j 个特征值归一化后的特征值.

对每个元组应用 $L1$ 范数归一化,提取元组内所有特征值,计算 $L1$ 范数:

$$L1_{norm} = |t| + \sum_{i=1}^m |W_i| + |P|, \tag{2}$$

其中, $\sum_{i=1}^m |W_i|$ 是气象特征的总和.

然后对元组内的每个特征进行归一化:

$$t' = \frac{t}{L1_{norm}}, \quad W'_i = \frac{W_i}{L1_{norm}}, \quad P' = \frac{P}{L1_{norm}}. \tag{3}$$

将归一化后的结果作为新的特征向量:

$$(t', W', P'). \tag{4}$$

通过归一化,各特征值位于统一的尺度内(通常 $[0, 1]$),确保时间、气象和功率特征的相对平衡,同时提高数据输入模型的适应性和预测修正精度. 这一流程将归一化作为数据融合的关键环节,是构建高效预测修正模型的重要基础. 归一化具体效果如图 2 所示,气象特征中蓝色曲线、黄色曲线和橙色曲线分别代表预处理前后辐照度、温度和湿度.

1.1.3 数据周期性特征提取

在功率预测中,功率和气象数据往往表现出显著的周期性,主要包含由昼夜变化引起功率输出波动的日周期、由季节变化引起周期性波动的年周期以及如天气变化(云层影响)导致短时波动的短周期. 因此,提取这些周期特征可以帮助建模时更好地捕捉数据的内在规律,提升预测精度.

通过傅里叶分解将时间序列数据分解为多个正弦和余弦波的叠加,每个波对应一个特定的频率和幅值,获得气象数据的初步周期性特征.

频率:反映数据中的周期性(例如每天的波动或每年的波动).

幅值:反映周期变化的重要性(例如日周期的幅值可能远大于短期扰动的幅值). 傅里叶分解的结果可以直观地揭示数据中的主要周期成分及其重要程度,从而为网格构建提供依据.

在分析对象的基础上,选取适当的采样频率;利用离散傅里叶变换将经处理的时间序列 $X(t)$ 转化成

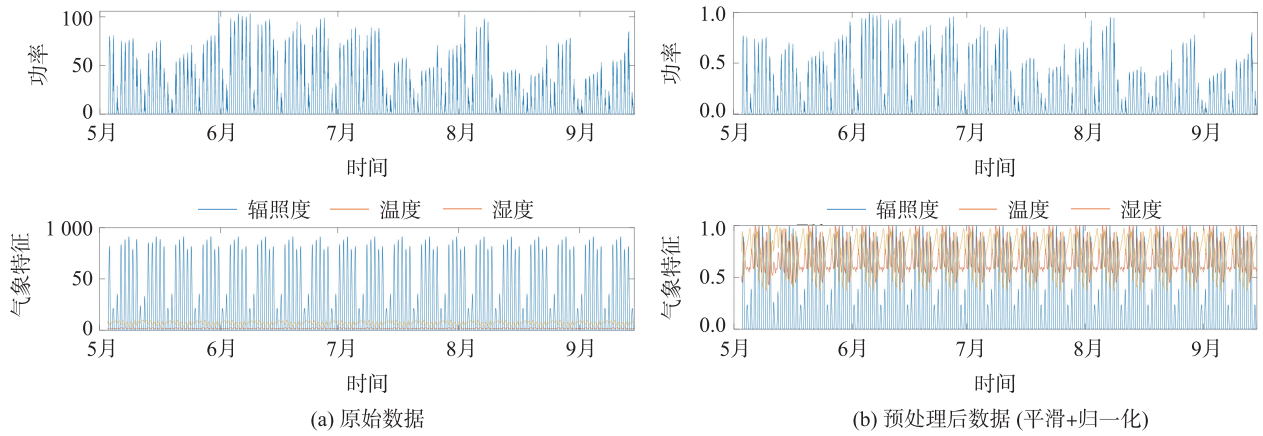


图2 处理前后数据对比

Fig. 2 Comparison of data before and after processing

频率域表达式:

$$X(f_k) = \sum_{t=0}^{N-1} X(t) \cdot e^{-j2\pi f_k t}, \quad (5)$$

其中, $X(f_k)$ 是频率 f_k 上的复数系数; $f_k = \frac{k}{N\Delta t}$ 是第 k 个频率分量; j 是虚数单位.

通过傅里叶分解,将时间序列转换到频域后,可以分析频谱,揭示数据中的周期性规律,计算频域信号的幅值 $|X(f_k)|$ 和功率 $(X(f_k))^2$.

$$|X(f_k)| = \sqrt{\text{Re}(X(f_k))^2 + \text{Im}(X(f_k))^2}. \quad (6)$$

功率谱 $(X(f_k))^2$ 描述了信号在不同频率上的能量分布. 峰值表示信号中的主要周期分量. 在功率谱中找到幅值最大的频率分量 f_k , 并计算对应的周期:

$$T_k = \frac{1}{f_k}, \quad (7)$$

其中, T_k 是周期, f_k 是频率.

通过傅里叶分解提取的主要频率分量,可以重构数据的周期性部分,用于后续特征提取或建模. 将主要频率分量的正弦和余弦波叠加,重构周期信号:

$$X_{\text{周期}}(t) = \sum_{k=1}^M A_k \cdot \sin(2\pi f_k t + \phi_k), \quad (8)$$

其中, $A_k = |X(f_k)|$ 是幅值,表示该频率分量的强度; $\phi_k = \arctan\left(\frac{\text{Im}(X(f_k))}{\text{Re}(X(f_k))}\right)$ 是相位; M 是主要频率分量的个数.

将重构的周期信号 $X_{\text{周期}}(t)$ 与原始信号 $X(t)$ 进行对比,验证周期性提取的效果:如果两者拟合良好,说明主要周期分量可以很好地描述数据中的周期性规律;如果存在较大偏差,可以考虑增加频率分量的个数 M . 周期特征提取后,将其与其他特征(如时间特征、气象特征)融合,构建完整的数据元组.

1.1.4 多元网格构建

在完成数据预处理和初步周期性特征提取后,需要对多维特征进行网格化处理,以便为后续滚动预测构建一个可操作的离散化特征空间. 多元网格构建的核心是基于时间特征、周期特征和功率特征,将其划分为离散区间,并通过笛卡尔积的方式形成时间网格、周期网格和功率网格的多元组合. 此网格结构可以有效地捕获特征间的关联性,并为动态建模提供基础.

(1) 时间网格构建:时间网格的构建基于数据的时间维度特性,将连续的时间数据按照一定规则划分为离散时间段. 根据研究需求,将时间轴按固定间隔划分. 例如,数据采样间隔为分钟级或小时级时,可将一天分为 N 个时间段. 将时间 t 的连续值映射到时间段区间.

$$t_{\text{区间}} = [t_{\text{start}} + k \cdot \Delta t, t_{\text{start}} + (k+1) \cdot \Delta t), \quad (9)$$

其中, Δt 为时间间隔. 离散后的时间特征将编码为离散网格的索引值, 例如 $t_i = 1, 2, \dots, N$.

(2) 周期网格构建; 周期网格通过提取的周期性特征(主周期和次周期)将数据映射到周期离散区间, 以捕获数据的周期性规律. 将主周期按等间隔划分为多个离散区间, 或根据次周期的显著性动态调整区间范围.

$$T_{\text{区间}} = \{ [0, T/N), [T/N, 2T/N), \dots, (N-1)T/N, T) \}, \quad (10)$$

其中, N 为划分的区间数.

(3) 功率网格构建; 功率网格是基于功率特征的历史分布和未来预测范围进行离散化处理, 构建网格以捕获功率特征的变化趋势. 首先统计功率值的分布范围 $[P_{\min}, P_{\max}]$, 如何按照等宽区间将功率范围划分为 M 个区间.

$$P_{\text{记周}} = \{ [P_{\min}, P_{\min} + \Delta P), [P_{\min} + \Delta P, P_{\min} + 2\Delta P), \dots, [P_{\min} - \Delta P, P_{\min}) \}, \quad (11)$$

其中, $\Delta P = (P_{\max} - P_{\min}) / M$.

时间网格、周期网格和功率网格离散化完成后, 将三者通过笛卡尔积的方式组合, 构建多维网格空间. 每个网格单元表示一个时间区间、周期区间和功率区间的特征组合:

$$\text{网格单元} = \{ (t_i, T_j, P_k) \}, \quad (12)$$

其中, t_i, T_j, P_k 分别为时间、周期和功率特征对应的离散区间索引值.

假设时间网格、周期网格和功率网格分别有 m, n 和 s 个区间, 则最终多元网格总数为 $m * n * s$. 每个数据点将被映射到一个网格单元中, 例如: 时间 $t = t_i$, 对应时间网格编码为 x_t ; 周期 $t \bmod 24 = t_i$, 对应周期网格编码为 x_T ; 功率 $P = P_k$, 对应功率网格编码为 x_P . 最终的网格单元为 $\{ (x_t, x_T, x_P) \}$.

通过多元网格构建, 将复杂时序数据转换成高维离散网格. 时间网格、周期网格和功率网格的联合构建, 不仅提升了特征捕获的精度, 还为滚动预测模型提供了明确的输入结构, 为后续卡尔曼滤波器的动态更新奠定了基础.

1.2 周期性网格动态滚动

1.2.1 卡尔曼滤波器

在构建多元周期性网格后, 为了提高模型对实时变化的适应性, 需要对网格进行动态更新. 通过引入卡尔曼滤波器, 将实时观测值与历史网格数据相结合, 对网格的初步周期规律和权重系数进行动态调整. 这种方法能够在复杂、多变的环境下保持高效预测性能, 同时实现对周期性规律的动态捕捉.

1.2.2 网格动态滚动

卡尔曼滤波器是用一种递推的方法来预测并修正动力系统. 该方法的基本思路是在系统状态空间模型的基础上, 通过对系统的状态进行预测与修改, 使其逐渐接近实际系统的状态. 在网格动态更新中, 卡尔曼滤波器用于实时调整网格模型, 使其能够反映新的气象数据与功率预测. 卡尔曼滤波器的工作可以分为两个主要步骤:

(1) 预测步骤: 基于上一时刻的状态和系统的动态方程, 预测当前时刻的系统状态.

(2) 更新步骤: 将观测数据与预测数据结合, 更新系统状态的估计值, 从而修正预测误差.

为了将卡尔曼滤波器应用到网格动态更新中, 我们首先需要为网格模型定义一个状态空间模型. 假设我们构建的网格模型包含三个主要维度: 时间(t)、周期(T)、功率(P), 每一个网格节点表示一个特定时间点、特定周期与功率的关系. 其中周期维度中又包含 1.1.3 节经傅里叶变换分解出来的功率幅值、频率以及气象因素等.

在卡尔曼滤波器的框架下, 网格模型的状态空间可以表示为状态向量 \mathbf{x}_k 和观测向量 \mathbf{z}_k .

状态向量 \mathbf{x}_k 表示当前时刻 k 的网格状态, 可以包括时间、周期和功率的预测值.

$$\mathbf{x}_k = \begin{bmatrix} t_k \\ T_k \\ P_k \end{bmatrix}. \quad (13)$$

观测向量 \mathbf{z}_k 表示观测到的实时数据, 通常为当前时间点的气象数据和功率输出.

$$z_k = \begin{bmatrix} t_{obs,k} \\ T_{obs,k} \\ P_{obs,k} \end{bmatrix}. \quad (14)$$

卡尔曼滤波器的工作流程包括以下几个步骤:初始状态设定、预测步骤和更新步骤.

在初始状态设定的过程中,首先,我们通过历史数据为每个时间周期、气象变量及功率值初始化状态向量 x_0 . 此外,定义状态转移矩阵 A 、观测矩阵 H 、过程噪声协方差矩阵 Q 和观测噪声协方差矩阵 R .

状态转移矩阵 A 描述了系统从一个时间步到下一个时间步的动态关系. 由于功率预测与气象数据之间具有线性关系,则可以通过历史数据估计出 A .

观测矩阵 H 描述了观测数据与状态变量之间的关系,通常为单位矩阵,表示每个状态变量都可以直接观察到.

过程噪声 Q 和观测噪声 R 代表了系统与观测过程中的随机误差,通常根据实际情况通过实验或数据拟合得到.

在预测阶段,基于当前状态向量 x_{k-1} 以及状态转换矩阵 A ,卡尔曼滤波器对下一时间的网格状态进行预测:

$$\hat{x}_k = A\hat{x}_{k-1}. \quad (15)$$

在此过程中,卡尔曼滤波器预测出新的网格状态,但此时并未考虑实际观测数据. 此时的预测值 \hat{x}_k 表示在没有新数据修正下,网格状态的预测值. 同时,预测误差协方差矩阵 P_k 也会随着时间推移而更新:

$$P_k = AP_{k-1}A^T + Q. \quad (16)$$

在更新步骤中,卡尔曼滤波器利用实时输入的数据(即观测数据 z_k)与预测数据 \hat{x}_k 进行融合,对网格点的状态进行校正. 首先,计算卡尔曼增益 N_k :

$$N_k = P_k H^T (H P_k H^T + R)^{-1}. \quad (17)$$

卡尔曼增益决定滤波器的更新权重,当卡尔曼增益较大时,意味着预测结果的不确定性较高或观测值更可靠,此时更新结果会更多地依赖观测值,从而迅速修正预测偏差. 反之,当卡尔曼增益较小时,说明预测结果的可信度较高或观测噪声较大,此时更新结果会更多保留预测值,以减少观测噪声对结果的影响.

然后,根据观测数据与预测数据之间的残差 $y_k = z_k - H\hat{x}_k$,更新网格状态:

$$\hat{x}_k = \hat{x}_{k-1} + N_k y_k. \quad (18)$$

通过这一过程,卡尔曼滤波器能够有效地调整预测误差并根据实时数据修正网格状态最后,更新后的误差协方差矩阵 P_k 为:

$$P_k = (I - N_k H) P_{k-1}. \quad (19)$$

在融合气象特征时,通过卡尔曼滤波框架对温度、湿度和辐照度进行动态加权,其中各特征的权重由实时计算的卡尔曼增益确定. 由于辐照度观测噪声最小且与功率高度相关,其卡尔曼增益最高;温度次之;湿度受间接作用与波动性影响,增益最低,该分布规律与光伏发电物理机理一致.

通过一系列的预测与更新步骤,卡尔曼滤波器确保了网格模型始终与实际观测数据保持一致,从而提高了系统的实时性与预测精度.

2 基于云模型的混合通道功率预测技术法

2.1 构建不确定性预测模型

2.1.1 云模型隶属度函数构建

本研究以李德毅院士于1990年代中期首次提出的“云模式”理论为基础,以“定性”与“量化”相结合的方式,对“定性”概念及其量化描述间的精细不确定关系展开深入研究. 本研究拟在云模式的框架下,通过融合期望值 E_x 、熵 E_n 和超熵 H_e 三类特征参数,构建深度神经网络模型,对电力负荷预测数据进行高维特征学习,增强模型非线性表征能力.

首先,以多元网格的功率预测数据为输入,构建云滴,并对反演云模式的三个数值特性进行求解.

期望:云滴分布的平均值,一个最好地表征了一个定性概念,也就是数据分配的一个参考点,它能够反

应出功率的主要趋势. 当输入样本满足或接近正态分布时,期望 E_x 可直接采用样本均值近似:

$$E_x \approx \bar{x} = \frac{1}{N} \sum_{i=1}^N x_i, \tag{20}$$

其中, $i=1,2,3,\dots,n$.

熵权法通过对光伏功率数据的离散性、模糊性进行量化,从而反映出功率预测的不确定特性;

$$E_n \approx s = \sqrt{\frac{\sum_{i=1}^N (x_i - \bar{x})^2}{N}}, \tag{21}$$

其中, k 为通过历史数据拟合得到的比例系数,并在固定应用场景中保持稳定.

超熵作为一种度量熵自身的不确定度,使其具有更强的层次结构和动态适应能力.

其次,利用正向云模式建立云图集,从时间和精准度两个方面分别确定云模型参数的左、右边界,并建立云模型的隶属函数. 图 3 显示了正向云发射体,其中 CG 即为云生成器模块,基于输入的权重系数与预测功率生成云滴,通过计算其期望(E_x)、熵(E_n)与超熵(H_c)来构建不确定性描述参数,为后续隶属度函数与通道分量处理提供输入依据.




图 3 正向云发射器

Fig. 3 Forward cloud emitter

2.1.2 通道间分量功率建模

将云模式与多元周期网格相结合,使混合通道模式具有更强的数据处理与预测能力. 该方法能够更加精确地辨识并利用多元周期性网格中的周期特性,从而体现出新能源功率预测数据的时空特性. 在对数据进行预处理之后,再对其进行识别和捕获,使其能够更加精确地掌握数据的动态变化.

每个通道中都含有海量的气象数据和功率资料,例如预测的精度(即预报值与实际值的距离)和误差(即预报值与实际值的偏离幅度). 本研究拟利用统计分析的方法,对多个通道的历史数据进行均值、标准偏差等指标进行统计分析,刻画各通道的平均水平与标准偏差,并通过对各通道的均值与标准偏差进行对比,从而更直观地认识信道间的性能差别,得出平均越高、标准偏差越小的通道,其预测效果越好,稳定性越好. 这样,就可以在以后的功率预报中,选取具有较好性能的信道,从而提高了预报的精度和可靠性.

2.2 分量优化与功率修正

分量优化主要关注于对云模型参数(E_x 、 E_n 、 H_c)以及多元周期性网格参数的调整,以最大化模型的预测性能.

功率修正旨在通过整合多源信息(如天气预报、设备状态监测等)和模型预测结果,对初步预测的光伏功率输出进行多变量协同校正,实现预测性能的双维度(精度与可靠性)提升. 具体实现流程图如图 4 所示.

3 仿真与结果分析

3.1 多元周期性网格建模验证

首先对前节提到基于已经接入的东润环能气象、国能日新气象、电科院北院气象、电科院南院等数据进行预处理以及归一化,其中包含气象特征数据(辐照度、温度、湿度等)和输出功率数据. 数据采集时间为 2024 年 6 月 1 日至 2024 年 8 月 3 日,时间跨度共 64 天,数据采样间隔为 15 min,总计 6 144 个数据点. 本文将数据集按时间顺序划分为训练集和测试集,其中前 44 天(6 月 1 日至 7 月 14 日)的数据作为训练集,后 20 天(7 月 15 日至 8 月 3 日)作为测试集,该比例兼顾了模型的学习样本量与泛化验证需求,用总样本 2/3 作为训练集、后 22 天作为测试集,可同时覆盖完整的气象与

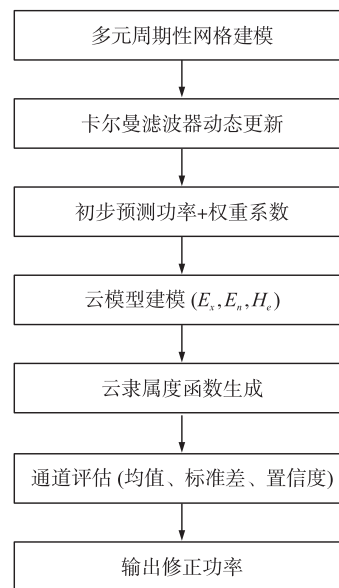


图 4 云模型混合通道功率修正流程图

Fig. 4 Flow chart of hybrid channel power correction in cloud

负荷周期,避免未来信息泄露.本文中光伏系统采用多晶硅组件,光电转换效率约为16%–18%,与所接入电站实测参数一致.在预测过程中,该效率被视为稳定常数并不参与动态调节.

从时间维度、周期特征维度、功率维度出发建立三个从属网格,使用多元归一特征形成时间网格、周期网格、功率网格的主网格.

对建立的网格形成历史网格数据输入至卡尔曼滤波器形成更新后的周期性规律,并持续生成最新的网格数据输入至模型进行训练,形成多元周期性网格的动态滚动.选取测试集中2024年7月15日6:00–12:00–18:00两个时间段进行至卡尔曼滤波器网格动态滚动验证,图5为初始网格以及多元周期性网格动态滚动示意图.




图5 多元周期性网格动态滚动示意图

Fig. 5 Schematic diagram of the dynamic rolling of the multivariate periodic lattice

在初始网络阶段图5(a)中,预测模型仅基于历史数据给出了初步功率估计,此时由于缺乏最新观测值的修正,特征分布较为分散,不确定性较高,卡尔曼增益(权重)取值相对较大,更新过程对观测值的依赖度较高,以快速校正预测误差.

进入12:00滚动更新阶段图5(b),模型已经历一轮观测修正,系统预测精度明显提升,特征分布开始收敛,卡尔曼增益呈下降趋势,更新结果更多保留了预测信息,显著降低了观测噪声带来的波动.

到18:00动态更新阶段图5(c),经过全天持续的权重自适应调整,网络状态已接近稳态分布,特征点云集中度更高,表明预测值与实际功率的偏差已被有效抑制.此时卡尔曼增益进一步降低,预测结果的平滑性与稳定性显著增强.

通过初始网格状态修正不同时间段的网格状态,并输出相应的预测结果,因此最终得到6:00–18:00预测功率与实际功率结果如图6所示.

通过计算各时刻预测与实际功率误差,来反映卡尔曼滤波器更新结果,得到图7所示的误差曲线.

最终通过动态滚动,不断更新权重,最终将经卡尔曼滤波器输出的初步预测值以及最新的权重输入给云模型来修正对应的预测值.

3.2 云模型混合通道预测结果分析

将通道优化后的光伏功率数据代入预测模型进行预测修正,最终预测功率、修正功率以及实际功率曲线对比如图8所示.

通过计算各时刻修正功率与实际功率的误差,来反映云模型混合通道修正结果,得到如图9所示的误




图 6 预测功率与实际功率曲线对比图

Fig. 6 Comparison of predicted power and actual power curve error curve.




图 7 预测功率与实际功率误差曲线图

Fig. 7 Predicted power and actual power error curve




图 8 预测、修正、实际功率曲线对比图

Fig. 8 Comparison of predicted, corrected and actual power curves




图 9 修正功率与实际功率误差曲线图

Fig. 9 Corrected power and actual power error curve

最终依据图 8 分别对预测功率、修正功率与实际功率进行误差分析,采用均方根误差 (Root Mean Square Error, RMSE) 和平均绝对误差 (MEAN ABSOLUTE ERror, MAE) 作为评估指标,具体量化方法的计算公式如式(22)-(23).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_{\text{实际}} - P_{\text{预测/修正}})^2}, \quad (22)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_{\text{实际}} - P_{\text{预测/修正}}|, \quad (23)$$

其中, $P_{\text{实际}}$ 表示光伏电站的实际发电功率, $P_{\text{预测/修正}}$ 表示基于本文方法得到的预测或修正后的发电功率.

图 6 至图 9 分别展示了本文模型与对比方法在不同测试场景下的预测误差曲线. 可以看出,本文方法在大多数时间段内的误差幅度明显较低,曲线波动也更为平稳;在功率突变点,误差能够在较短时间内迅速回落,表现出较强的跟踪与修正能力. 通过对曲线的整体走势与关键时刻误差值进行对比,可以发现本文方法不仅在稳态阶段维持了较小的误差,而且在不利天气或强波动条件下,仍能有效限制误差峰值的出现频率和持续时间. 这说明本文方法在保证预测精度的同时,还具备较高的鲁棒性和对突发变化的自适应能力,其预测结果在不同场景下都表现出更优的稳定性与可靠性.

表 1 中误差对比充分证明了在云模型混合通道修正下的功率预测方法具有准确性和可靠性. 不仅验证了多元周期性网格捕捉动态特征能力的优越性,而且体现了云模型在处理复杂、不确定性数据方面的优势.

表 1 功率误差对比

Table 1 Power error comparison		
误差指标功率	RMSE	MAE
预测-实际	5.33	4.17
修正-实际	3.73	2.92

4 结论

针对传统功率预测无法在不同时间尺度和多元因素的影响下进行准确地预测的问题,本文通过多元周期性网格结合云模型混合通道的创新思路,对预测的精度进行提升. 最终通过仿真得出结论如下:

(1)通过卡尔曼滤波器更新的多元周期性网格,能够实时适应复杂环境变化,精确捕捉时空动态特

征,实现对周期特征的动态调整与优化.

(2)结合云模型混合通道的隶属度函数与概率修正优化,实现了多尺度信息的融合与动态调整,提升了新能源功率预测在时空双维度下的准确性和稳定性.

本文方法在预测效果上表现出较高的精度与稳定性,但仍有进一步优化的空间.未来研究可引入更长时段、多季节、跨年度的历史运行数据,以验证模型在更复杂、不同时空条件下的泛化能力与适应性.同时,将本文方法与近年来发展迅速的深度学习模型进行对比与融合,有望在保持物理可解释性的前提下进一步提升预测精度.

[参考文献]

- [1] 周孝信,赵强,张玉琼,等. “双碳”目标下我国能源电力系统发展趋势分析:绿电替代与绿氢替代[J]. 中国电机工程学报,2024,44(17):6707-6721.
- [2] 负保记,张恩硕,张国,等. 考虑综合需求响应与“双碳”机制的综合能源系统优化运行[J]. 电力系统保护与控制,2022,50(22):11-19.
- [3] 陈运蓬,景超,白静波,等. 基于集成学习的新能源发电功率预测[J]. 太阳能学报,2024,45(6):412-421.
- [4] 周海锋,徐伟,沙立成,等. 考虑新能源不确定性的调度计划安全稳定校核方法[J]. 电力工程技术,2024,43(3):63-70.
- [5] Wolff B, Kühnert J, Lorenz E, et al. Comparing support vector regression for PV power forecasting to a physical modeling approach using measurement, numerical weather prediction, and cloud motion data[J]. Solar Energy,2016,135:197-208.
- [6] Dimd B D, Völler S, Midtgård O M, et al. Quantification of the impact of azimuth and tilt angle on the performance of a PV output power forecasting model for BIPVs[J]. IEEE Journal of Photovoltaics,2023,14(1):194-200.
- [7] 陈颖,孙荣富,吴志坚,等. 基于统计升尺度方法的区域风电场群功率预测[J]. 电力系统自动化,2013,37(7):1-5.
- [8] Lydia M, Kumar S S, Selvakumar A I, et al. Linear and non-linear autoregressive models for short-term wind speed forecasting [J]. Energy Conversion and Management,2016,112:115-124.
- [9] 周文,孟良,杨正富,等. 基于时间序列的大型光伏电站发电短期预测[J]. 电源技术,2021,45(11):1490-1494.
- [10] 李逸航,肖辉,易纯,等. 基于STL分解和TPA机制的光伏功率区间预测[J]. 太阳能学报,2024,45(12):22-29.
- [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] 叶林,裴铭,李卓,等. 风电和光伏发电功率联合预测与预调度框架[J]. 高电压技术,2024,50(9):3823-3836.
- [13] 陈殿昊,臧海祥,蒋雨楠,等. 基于多层次云图特征与宽度学习的超短期光伏功率预测[J]. 电力系统自动化,2024,48(22):131-139.
- [14] 贺亦琛,师长立,郭小强,等. 基于参数优化多核支持向量机的光伏功率预测算法[J]. 太阳能学报,2024,45(9):394-404.
- [15] 常青松,杨昭,杨熠辉,等. 基于相似日聚类的超短期光伏功率组合预测模型[J]. 热力发电,2023,52(11):123-131.
- [16] 张程珂,刘会灯,朱渝宁,等. 基于多特征分析提取的随机森林超短期光伏功率预测[J]. 电力需求侧管理,2023,25(6):50-56.
- [17] 刘志超,袁三男,唐万成. 基于BLSTM-随机森林的短期光伏发电输出功率预测[J]. 电源技术,2021,45(4):495-498.
- [18] 杨茂,王东,严干贵,等. 风电功率波动特性中的周期性研究[J]. 太阳能学报,2013,34(11):2020-2026.
- [19] 乔颖,孙荣富,丁然,等. 基于数据增强的分布式光伏电站群短期功率预测(二):网格化预测[J]. 电网技术,2021,45(6):2210-2218.
- [20] 战文华,车建峰,王勃,等. 基于网格化数值天气预报的区域光伏发电多输出功率预测方法[J]. 中国电力,2024,57(3):144-151.

[责任编辑:陆炳新]