

基于MFM-CG-DBN模型的高渗透率光伏微电网 发电功率短期预测

徐小明¹, 王占海²

(1. 新乡职业技术学院智能制造学院, 新乡 453006; 2. 衡水学院电子信息工程学院, 衡水 053000)

摘 要: 为提升高渗透率光伏微电网发电功率预测精准度, 提出一种改进马尔科夫链位移时序预测法(MFM), 用以优化共轭梯度法(CG)-深度信念网络(DBN)组合预测模型(CG-DBN)存在的特征提取不充分、预测不精确问题。首先, 借助 Pearson 相关系数分析高渗透率光伏微电网发电功率的影响因素; 其次, 借助马尔科夫链位移时序预测法具有的无后效性特点, 将残差修正过程应用于 CG-DBN 预测模型, 构建 MFM-CG-DBN 高渗透率光伏微电网发电功率短期预测模型; 最后, 利用 MFM-CG-DBN 短期预测模型对晴天、多云与雨天 3 类型天气下的高渗透率光伏微电网发电功率数据进行仿真。仿真结果显示, 所提短期预测模型较传统 CG-DBN 短期预测模型具有更高预测精度, 可满足高渗透率光伏微电网发电功率预测需求。

关键词: 马尔科夫链; 微电网; 光伏发电; 高渗透率; MFM-CG-DBN

中图分类号: TM73

文献标志码: A

0 引 言

作为分布式可再生能源友好接入大电网的一种方式, 高渗透率光伏微电网以太阳能这一清洁能源为主要发电方式, 具备建设周期短、安全性高、地域空间限制因素少等优势^[1], 日渐成为未来能源供应的关键。同时需要看到, 由于受光照、气候等多元化因素影响, 高渗透率光伏微电网输出功率面临较大的不确定性和较强的波动性^[2], 难以为输出可靠电能提供持续来源。设计有效的高渗透率光伏微电网短期预测技术, 对于有效利用光伏能源、保持能源稳定供应至关重要。在此背景下, 如何精准地预测高渗透率光伏微电网短期发电情况, 已成为现阶段学术界关注的焦点。

当下, 主流文献主要依靠物理方法或统计方法对光伏微电网发电功率进行预测^[3]。其中, 物理方法强调仅借助物理模型对投入运行后的光伏系统发电功率进行预测, 这一过程并不依赖历史运行数据^[4]。由于对光伏电站物理信息依赖性较大, 物理方法的预测精度受所建模型影响较强, 在光伏发电功率预测领域应用范围狭小。统计方法是借助统计学工具梳理光伏系统历史运行数据后, 梳理出光伏输出功率并建立起其与各影响因素之间内在联系的一种常用工具^[5]。现实而言, 光伏输出功率预测需积累一定时间的历史数据, 通常为 3 个月到 1 年。而处于投运初期, 光伏微电网的历史数据积累量较小, 这导致传统统计方法在测度光伏微电网发电功率时会受到较大限制^[6]。因此, 需对传统统计方法加以优化,

使之适用于高渗透率光伏微电网系统发电功率短期预测活动。

近年来, 有学者通过建立组合模型对光伏发电功率进行预测, 一定程度上规避传统单一模型不足问题, 有效提升模型预测结果精度^[7]。特别是共轭梯度法(conjugate gradient, CG)与深度信念网络(deep belief network, DBN)组合预测模型在光伏微电网发电功率预测上取得明显成果。文献[8]构建了 CG-DBN 组合预测模型, 即根据类别进行 CG-DBN 预测模型建模, 对光伏输出功率进行短期预测活动, 发现 CG-DBN 组合预测模型的光伏功率预测性能优于其他模型。然而, 该研究所提预测模型的预测结果波动较大, 精准性仍有待提升。鉴于马尔科夫链位移时序预测法(Markov forecasting model, MFM)具备无后效性优势, 能够化解预测波动性大的难题, 多数研究开始将 MFM 算法中的误差修正思想应用于更多残差修正过程。文献[9]借助 MFM 算法对不同国家制造业显示性比较优势指数的截面动态变化进行了分析, 认为 MFM 算法具有较强误差修正能力; 文献[10]采用马尔科夫链模型构建自然风风向变化的转移概率矩阵模型, 在此基础上生成随机时间序列展开反向验证, 发现马尔科夫链能够有效解决风向预测问题。

综上, 现有文献使用复合模型对光伏微电网发电功率进行了短期预测, 取得良好效果, 但仍缺乏一定的精准度。实际上, 相较于单一模型, 采用组合模型对高渗透率光伏微电网短期发电功率进行预测具有更强适用性、更高精准度。但

同时,由于数据收到外界随机因素干扰,组合模型预测的精度受到极大限制。鉴于此,本文立足前人研究,将 CG-DBN 与马尔科夫链位移时序预测法(MFM)相结合,构建基于马尔科夫链位移时序预测法修正的短期预测模型(MFM-CG-DBN),并对不同天气状况下的高渗透率光伏微电网发电功率进行预测。首先,借助 Pearson 相关系数,测得高渗透率光伏微电网发电功率与影响因素之间的相关性,由此得出关键性指标;其次,提出改进的马尔科夫链位移时序预测法,对 CG-DBN 进行优化,继而建立起 MFM-CG-DBN 短期预测模型;最后,基于晴天、多云与雨天 3 种不同类型天气,选取由河南省河南豫光金铅股份有限公司运营的工业绿色微电网项目(下称“绿色微电网项目”),对该项目发电功率展开仿真实验,并与 CG-DBN 短期预测模型进行对比分析。创新之处在于,本文使用的 MFM-CG-DBN 短期预测模型有效解决 CG-DBN 短期预测模型预测精度较低问题,可为高渗透率光伏微电网发电功率预测提供重要参照。

1 高渗透率光伏微电网发电功率的影响因素

高渗透率光伏微电网发电功率受太阳辐照度、温度、湿度、风速等多重气象因素影响,存在一定的不稳定性。为减小高渗透率光伏微电网发电功率预测结果与真实值之间的误差,理论上预测模型应将各类气象因素纳入考虑范围。然而,由于各类气象因素对发电功率的影响存在一定差异^[11],过少的气象因素可能导致预测模型难以精准反映实际情况,过多的气象因素会增加预测模型复杂度并耗费更多计算资源,甚至降低预测模型的鲁棒性^[12]。此时,若不加筛选预测模型的输入变量,会导致高渗透率光伏微电网发电功率预测模型得出结果冗余与偏差^[13]。故而,在训练模型之前,需对高渗透率光伏微电网发电功率影响因素进行筛选。本文采用 Pearson 相关系数分析方法,筛选历史数据中影响高渗透率光伏微电网发电功率的最优几类气象因素,并将这些因素作为输入变量,验证不同气候类型与高渗透率光伏微电网发电功率之间关联性^[14]。Pearson 相关系数求解公式见式(1):

$$d = \frac{\sum_{i=1}^n (A_i - \bar{A})(B_i - \bar{B})}{\sqrt{\sum_{i=1}^n (A_i - \bar{A})^2} \sqrt{\sum_{i=1}^n (B_i - \bar{B})^2}} \quad (1)$$

式中: d ——两变量间的相关系数; A_i, B_i ——第 i 组数据两个因素值; $\bar{A}, \bar{B}$ ——两个因素的均值; n ——数据组的数量。

为检验所构建预测模型预测的有效性,选择绿色微电网项目光伏发电月度功率数据与气象数据,得到不同类型气象因素与高渗透率光伏微电网发电功率间 Pearson 相关系数(见表 1)。分析表 1 数据发现,高渗透率光伏微电网发电功率与太阳辐照度、大气温度、风速为高度正相关关系,与相对

湿度呈明显的负相关,而与大气压强无明显相关性。

表 1 不同气象因素与高渗透率光伏微电网发电功率间的相关系数

Table 1 Correlation coefficient between different meteorological factors and power generation of high penetration photovoltaic microgrids

气象因素	Pearson 相关系数
太阳辐照度	0.953
大气温度	0.461
风速	0.156
相对湿度	-0.572
大气压强	0.005

为验证上述相关性结果是否可靠,进一步绘制了“绿色微电网”项目的不同气象因素与高渗透率光伏微电网发电输出功率的曲线,结果见图 1a~图 1d。需要说明的是,曲线图仅列示了单一气象条件与高渗透率光伏微电网输出功率的变化(数据采样间隔为 15 min)。主要原因如下:第一,从太阳辐照度看,鉴于光伏微电网发电主要借助光伏组件将辐射能量转化为电能,现阶段光伏发电单元的发电功率主要与辐照度、光伏单元参数及其表面温度等有较大的关联性^[15]。在无故障运行情况下,光伏单元参数(面板倾角、光伏组件转化效率等)及其表面温度对光伏发电功率预测精准性偏差的负面影响可忽略不计^[16]。对比而言,太阳辐照度是决定光伏发电功率的主要因素^[17]。因此,仅绘制太阳辐照度与高渗透率光伏微电网输出功率之间关系的曲线以验证相关性结果。第二,从气象因素看,天气类型、云层遮挡等气象状态虽影响光伏微电网输出功率,但由于这类因素具有抽象性、模糊性因此难以量化。文献[18]选取晴天、雨天、多云 3 种状态,探讨气候因素与光伏微电网输出功率的相关性,并进行发电功率预测。晴天下,高渗透率光伏微电网发电环境的光照较充足,温度相应较高,对应的光伏微电网发电功率较高;雨天下,高渗透率光伏微电网发电环境具有水汽较多、空气透光性相对不足,光伏微电网发电功率随之降低。可以说,大气温度、湿度、风速能够分别对应晴天、雨天及多云 3 种状态。为此,在不考虑其他外在气象因素或组合因素情况下,本文依次绘制大气温度、相对湿度、风速分别与高渗透率光伏微电网输出功率关系的曲线,以检验上述相关性结果是否可靠。

如图 1a 所示,太阳辐照度和高渗透率光伏发电微电网发电功率二者之间呈正相关关系,即太阳辐照度的提高会提升高渗透率光伏发电微电网发电功率,反之,太阳辐照度降低会降低高渗透率光伏发电微电网发电功率。当太阳辐照度接




图1 高渗透率光伏发电微电网发电功率影响因素的 Pearson 相关系数

Fig. 1 Pearson correlation coefficient of affecting factors of output power of high penetration photovoltaic microgrids

近 0(凌晨或夜晚),高渗透率光伏发电微电网发电功率也为 0,且太阳辐照度在 720 W/m^2 时,高渗透率光伏发电微电网发电功率达到最大值。由表 1 结果可知,二者相关系数超过 0.9。综合来看,太阳辐照度正向影响高渗透率光伏发电微电网发电功率。

如图 1b 所示,温度对高渗透率光伏发电微电网发电功率的影响呈现波动走势。伴随温度不断提升,即在 $10\sim 60^\circ\text{C}$ 时,高渗透率光伏发电微电网发电功率处于上升态势;在 75°C 时,高渗透率光伏发电微电网发电功率达到最大值;而后,随着温度不断降低,高渗透率光伏发电微电网发电功率也在持续降低。进一步从时间领先情况来看,高渗透率光伏发电微电网发电功率的变化时间落后于温度变化时间,即与温度到达峰值时间相比,高渗透率光伏发电微电网发电功率要滞后到达峰值,意味着二者之间存在一定时间滞后性。结合表 1 结果发现,温度对高渗透率光伏发电微电网发电功率亦产生正向影响。

如图 1c 所示,在 $50\%\sim 60\%$ 的相对湿度环境下,高渗透率光伏发电微电网发电功率低于 15 kW 。伴随湿度不断下降,高渗透率光伏发电微电网发电功率逐步提升。在 $30\%\sim 40\%$ 的相对湿度环境下,高渗透率光伏发电微电网发电功率虽有一定起伏,但其数值始终高于 25 kW 。此后,伴随相对湿度变化幅度减小,高渗透率光伏发电微电网发电功率仍处于下降走势。因此而言,随着相对湿度减小,高渗透率光伏发电微电网发电功率反而增加,即二者之间存在负相关关系。

如图 1d 所示,由于风速变化随机性较大,高渗透率光伏发电微电网发电功率的变化趋势同样处于不稳定态势,增减幅度并未呈现一定的规律性。且从表 1 相关系数可知,风速与光伏发电功率的相关性极低,可忽略不计。对此,在预测高渗透率光伏发电微电网发电功率时,剔除风速这一因素。

最终,将输入参数确定为太阳辐照度、温度与相对湿度,输出参数为高渗透率光伏发电微电网发电功率。

2 高渗透率光伏微电网发电功率的短期预测模型设计

2.1 基于 CG-DBN 的光伏微电网发电功率短期预测模型

在对高渗透率光伏微电网展开优化调度工作前,需明确典型特征,据此预测该电网光伏发电功率。深度信念网络(DBN)由多个受限玻尔兹曼机构成,其采用无监督预训练算法对各隐藏层神经元逐层训练,并依据输入特征变量优化隐藏层神经元,属于一种深度学习方法^[19]。DBN 预测模型能够适应多层次挖掘数据特征要求,是预测光伏输出功率的有效工具。但 DBN 缺乏无监督逐层训练权重,会导致其学习速度较慢。而 CG 法通过展开 n 维寻优的数学方法,可解决 DBN 算法复杂、构建预测模型速度较慢的问题,逐步成为解决大型线性问题的有效替代方案。因此,文献[20]构建 CG 和 DBN 组

合预测模型并进行光伏发电功率预测。

细言之,以 CG-DBN 方法预测光伏发电功率的具体流程如下:1)先对数据进行补齐、归一化,其次将 45% 的数据设置为对照组,另外 55% 的数据设为干预组。在此过程中,主要采用相似日样本集作为训练样本。2)明确初始模型的输入层节点数量、隐含层节点数量及其层数。3)确定各层节点权重。在 DBN 网络中,各层节点数据都有一个权重,该权重表示这一输入数据对最终结果的重要性。进一步地,采用层次分析进行具体计算。4)通过全局更新法确定网络中其他参数,包括迭代搜索方向、搜索步长、更新参数等内容,据此建立初步 DBN 模型。5)借助 CG 算法对初步的 DBN 模型进行寻优。本文通过随机选取训练集对每一个神经元 RBM 进行训练。当第一个神经元 RBM 节点状态发生变动后,可将其输出视为第二个神经元 RBM 的输入,并对此开展第二层神经元 RBM 训练。至此,依据从上到下顺序,将所有神经元 RBM 进行更新。最后,对更新后的网络权重进行收敛性检验。当权重更新幅度低于预设阈值且模型误差趋于稳定时,认为 DBN 模型达到收敛状态;否则继续进行训练和参数优化,直至满足停止条件。6)完成上述步骤后,建立预测模型。以上步骤见图 2。




图2 基于CG-DBN的光伏微电网发电功率预测流程

Fig. 2 Power generation prediction process for photovoltaic microgrids based on CG-DBN

2.2 MFM预测法

需要关注到,所提 CG-DBN 预测模型在光伏微电网发电功率的预测方面具有一定精准性,但仍无法避免预测结果波动较大的情况^[21],较难应用于高渗透率光伏微电网发电功率预测领域。马尔科夫链位时序预测法(MFM)是以事件当前发展态势为前提,通过一系列行动特征预测其将来各时刻变动的一种预测工具^[22]。该方法立足事物不同状态,通过对

初步概率、状态之间转移概率进行分析,从而了解事件状态变化趋势,以此为依据预测事物未来演变趋势。其中,转移概率(P)是指某一系统由一个时期所处的状态 L_i 转变为未来所处可能状态 L_j 的可能性^[23]。从分类来看,转移概率分为一次转移和多次转移。若存在一个离散型的随机过程,将其所有可能状态集合设置为 $L = \{1, 2, \dots, N\}$ 。若对于任意的 $n > 1(i_1, i_2, \dots, i_{n-1}, j \in L)$,恒有:

$$\begin{aligned} P\{C_1 = i_n, C_2 = i_2, \dots, C_{n-1} = i_{n-1}\} \\ = P\{C_n = j | C_{n-1} = i_{n-1}\} \end{aligned} \quad (2)$$

此时,可将离散模型随机过程 $\{C_t, t \in T\}$ 称之为马尔科夫链。进一步将各状态之间的一步转移概率排为矩阵,称之为状态矩阵:

$$P = \begin{bmatrix} p_{11} & \cdots & p_{1n} \\ \vdots & \ddots & \vdots \\ p_{n1} & \cdots & p_{nn} \end{bmatrix} \quad (3)$$

每个状态 i 对应状态矩阵 P 的第 i 行。

由此,得出马尔科夫链预测模型表达式:

$$x(n) = x(0)P^{(n)} \quad (4)$$

式中: $x(n)$ —— n 时刻的状态概率向量; $x(0)$ ——初始时刻的状态概率向量; $P^{(n)}$ ——状态转移概率矩阵。

2.3 基于MFM-CG-DBN的高渗透率光伏微电网发电功率短期预测模型构建

MFM 预测法可解决预测模型随机波动性较大的难题,被大范围应用于预测模型残差修正过程^[24]。为提升 CG-DBN 短期预测模型的预测精准性,采用 MFM 预测法的误差修正思路,及时优化 CG-DBN 预测模型,构建基于 MFM-CG-DBN 高渗透率光伏微电网发电功率短期预测模型,具体运作流程见图 3。




图3 基于MFM-CG-DBN高渗透率光伏微电网发电功率短期预测模型运作流程

Fig. 3 Operation process of short term prediction model for high penetration photovoltaic microgrid power generation based on MFM-CG-DBN

具体步骤:1)构建残差序列。依据 CG-DBN 测试样本预测值与实际值测得相对误差,进而构建残差序列

$o = [o(1), o(2), \dots, o(n)]$ 。

2) 确定初始状态。采用均值-标准差法, 将初始状态划分为 5 个层面: $F_1(-\infty, \bar{o} - S)$, $F_2(\bar{o} - S, \bar{o} - 0.5S)$, $F_3(\bar{o} - 0.5S, \bar{o} + 0.5S)$, $F_4(\bar{o} + 0.5S, \bar{o} + S)$, $F_5(\bar{o} + S, \bar{o} + \infty)$ 。

3) 计算残差序列各阶自相关系数 e_k 和对应权重 w_k :

$$e_k = \frac{\sum_{t=1}^{n-k} (o_t - \bar{o})(o_{t+k} - \bar{o})}{\sum_{t=1}^n (o_t - \bar{o})^2} \quad (5)$$

$$w_k = \frac{|e_k|}{\sum_{k=1}^n |e_k|} \quad (6)$$

式中: e_k ——第 k 阶段自相关系数; o_t —— t 时刻样本数量。

4) 确定状态转移概率矩阵。此时, 将转移概率矩阵设定为:

$$p_{ij} = \frac{q_{ij}}{\sum_{j=1}^5 q_{ij}} \quad (7)$$

式中: q_{ij} ——转移频率矩阵的第 i 行第 j 列的具体数值。

此时, 转移频率矩阵公式为:

$$q_{ij} = \begin{bmatrix} q_{11} & \cdots & q_{1j} \\ \vdots & \ddots & \vdots \\ q_{i1} & \cdots & q_{ij} \end{bmatrix} \quad (8)$$

5) 测得预测日残差所在状态概率 P_i^k , 将同一状态不同步长的预测概率分别与各自对应权重相乘, 进而求得得出各状态概率公式:

$$P_i^k = \sum_{k=1}^h w_k P_i^k \quad (9)$$

6) 最终预测值为 $H_y = H_{y_0}(1 - \kappa)$ 。其中, H_y 为经加权 CG-DBN 修正后的最终预测值 (MW), H_{y_0} 为 CG-DBN 预测模型的预测值 (MW); 为步骤 5) 中的未来状态上下限的均值。

3 算例仿真与结果分析

3.1 数据预处理

为检验所述模型能否有效提高晴天与非晴天条件下的预测精度, 使用中国国家气象中心公开发布的中国气象站点河南省新乡市 2022 年气候与太阳辐射数据, 并将其制作为训练集训练模型。作为对比, 选取河南省新乡市工业绿色微电网项目 2023 年全年红外地基云图、太阳辐射度和气象信息, 将此信息制作为验证集, 检验模型的有效性。其中, 每组数据以天 (d) 为单位, 数据间隔以秒 (s) 为单位, 每个时间戳对应相同时刻的功率数据和环境数据。在研究过程中, 还需考虑不同类型天气下 96 点高渗透率光伏发电微电网发电功率变动情况。为此, 选择 2023 年 9 月 19 日 (雨)、23 日 (晴)、27 日 (多云) 06:00—19:00 的发电功率进行提前 1 h 预测, 取

时间间隔为 15 min, 每天数据的取样点为 88 个。预测日气象相关信息如表 2 所示。

为验证所提模型的有效性和科学性, 将 MFM-CG-DBN 短期预测模型设为模型 1, CG-DBN 短期预测模型设为模型 2, 并对二者测得的高渗透率光伏微电网发电功率值进行对比分析。

表 2 预测日气象信息

Table 2 Meteorological information on predicting days

日期	类型	太阳辐射峰值/均值/ (W/m ²)	温度 峰值/ 均值/°C	湿度 均值/%
2023-9-19	雨天	674/461	15.4/10.8	93
2023-9-23	晴天	1064/763	24.6/18.5	36
2023-9-27	多云	896/682	17.6/13.4	49

考虑到众多气象因素对光伏发电功率产生较大程度影响^[25], 监测设备采集的数据可能遭遇通信故障, 继而出现丢失问题。这不仅阻碍后续模型的顺利进行, 还会增加研究人员的工作难度, 进而产生预测结果与实际偏差等问题。因此, 在建模前需对数据进行质量控制。原始数据质量控制方案为: 1) 剔除 0 数据与常量数据, 即通过一阶差分方法剔除曲线表现为 0 和恒定常数的数据。2) 剔除方向变化不一致的数据, 即利用协方差系数设定阈值, 在此基础上剔除局部变化差异较大或变化趋势相反数据。

此外, 鉴于不同气象参数之间的量级、方向会有较大差异, 为提升发电功率预测的精准性, 需及时消除这些差异。为此, 运用线性函数对数据展开归一化处理:

$$Y_{\text{nor}} = \frac{Y - Y_{\min}}{Y_{\max} - Y_{\min}} \quad (10)$$

式中: Y_{nor} ——归一化之后的数值; Y ——初始数据; $Y_{\max}$ 、 $Y_{\min}$ ——数值的最大值和最小值。

3.2 MFM-CG-DBN 短期预测模型参数

MFM-CG-DBN 短期预测模型参数主要包括输入变量与输出两部分内容。将预测日的气象数据与高渗透率光伏微电网历史发电功率设为预测模型的输入变量。在输入变量方面, 选取太阳辐射度、相对湿度、温度 (以每日平均数值为准); 在输出变量方面, 选择历史发电功率数据选择与预测日相似度最高一天作为输出功率序列。

3.3 MFM-CG-DBN 短期预测模型评价标准

为提升高渗透率光伏微电网发电功率预测精准性, 借助相对平均绝对误差 (E_{cd})、平均绝对误差百分比 (E_{mr})、相对均方根误差 (E_{ms}) 与拟合系数 (R^2) 对仿真结果进行分析。具体计算公式为:

$$E_{\text{cd}} = \frac{|u_i - u_i'|}{u_i} \times 100\% \quad (11)$$

$$E_{MT} = \frac{1}{N} \sum_{i=1}^N \frac{|u_i - u'_i|}{u_i} \times 100\% \quad (12)$$

$$E_{MS} = \sqrt{\frac{1}{N} \sum_{i=1}^N (u_i - u'_i)^2} \times 100\% \quad (13)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (u_i - u_i')^2}{\sum_{i=1}^n (u_i - \bar{u})^2} \quad (14)$$

式中: u_i ——第 i 次高渗透率光伏发电功率真实值, kW; u'_i ——第 i 次高渗透率光伏发电功率预测值, kW; N ——样本数量。

其中, E_{CD} 、 E_{MT} 数值越小, 代表预测值与实际值之间差距较小, 预测准确度越高, 可信度也就越好; R^2 趋近于 1, 表明模型拟合度越高, 趋向于 0 则表明拟合程度越低。

3.4 结果分析

3.4.1 实验数据处理

为验证 MFM-CG-DBN 短期预测模型的有效性, 将 3.1 节筛选出的样本数据输入 MFM-CG-DBN 短期预测模型以及 CG-DBN 短期预测模型, 选取 2023 年 9 月 19 日、23 日和 27 日 3 d, 对“绿色微电网”项目的高渗透率光伏微电网发电功率进行测度。

3.4.2 晴天天气下高渗透率光伏微电网发电功率预测

运用模型 1 与模型 2 对测试样本进行预估, 求得每日同一预测点的残差, 并将其作为样本修正预测日该点预测结果。首先, 采用均值-标准差分级法, 得到模型 1、模型 2 的残差序列均值分别为 $M=6.86$ 、 7.03 , 标准差分别为 7.6649 、 7.0661 。在此基础上, 根据状态转移统计学方法确定高渗透率光伏发电功率状态转移概率矩阵。进一步根据式(9)计算残差所在状态概率, 得到对应 η 值分别为 6.06 和 5.79 。

从表 3 结果可知, MFM-CG-DBN 短期预测模型的 E_{CD} 、 E_{MT} 与 E_{MS} 值分别为 4.79 、 1.24 与 1.88 , 低于 CG-DBN 短期预测模型数值, 说明该模型的预测效果最好; R^2 数值为 0.97 , 表明模型拟合度较高。如图 4a 所示, 晴天天气下模型 1 预测功率为 3.5103 kW, 实际功率为 3.5016 kW, 而模型 2 预测功率值为 3.9336 kW, 相对误差分别为 0.0087 和 0.4320 。表明模型 1 误差波动性更小, 与曲线光伏发电功率的真实值的贴合度高。综合来说, 模型 1 较好地提升了发电功率的预测精度。

3.4.3 多云天气下高渗透率光伏微电网发电功率预测

多云天气状况下, 模型 1、模型 2 的预测误差修正具体过程近似于晴天天气, 二者之间的预测误差修正流程相同。通过运算并从表 3 结果可知: 对比晴天天气, 多云天气下模型 1 的 E_{CD} 、 E_{MT} 与 E_{MS} 值均低于模型 2, 表明模型 1 的预测偏误较低, 即 MFM-CG-DBN 模型的预测结果更贴近实际值。

表 3 不同天气类型中 MFM-CG-DBN 预测模型发电功率的误差对比


Table 3 Comparison of errors in MFM-CG-DBN prediction models for power generation in different weather types

类型	预测模型	$E_{CD}/\%$	$E_{MT}/\%$	$E_{MS}/\%$	R^2
晴天	1	4.79	1.24	1.88	0.97
	2	5.42	3.73	2.11	0.91
多云	1	3.13	2.91	2.46	0.98
	2	5.00	3.62	3.11	0.93
雨天	1	1.05	1.03	0.39	0.96
	2	1.46	1.76	0.67	0.93


如图 4b 所示, 多云状态下, 模型 1 在 11:00 和 14:00 时发电功率预测值较高, 分别为 2.4312 、 2.9081 kW; 模型 2 在这两个时刻的发电量预测值分别为 2.7025 、 3.1318 kW; 实际值分别为 2.5712 和 2.9103 kW。表明模型 1 误差波动性较小, 且与曲线光伏发电功率的真实值贴合度高。因此, 模型 1 较好地提升了多云天气下发电功率的预测精度。

3.4.4 雨天天气下高渗透率光伏微电网发电功率预测

结合晴天天气下高渗透率光伏微电网发电功率预测流程, 获得雨天天气下两大模型发电功率预测值。从表 3 结果可知, 雨天天气下模型 1 的 E_{CD} 、 E_{MT} 与 E_{MS} 值均低于模型 2。如图 4c 所示, 雨天时, 高渗透率光伏微电网发电功率预测波动较大, 发电功率偏低。与晴天、多云两类天气类型相比, 模型 1



a. 晴天



b. 多云




图4 不同天气类型下预测模型发电功率的误差对比曲线

Fig. 4 Error comparison curves of power generation of prediction models under different weather types

和模型2在雨天状态下的预测结果与真实值的偏差较大,多个预测点的波动情况更明显。综合而言,模型1预测的高渗透率光伏微电网发电功率值更加贴近真实情况,表明MFM-CG-DBN短期预测模型较CG-DBN短期预测模型具有更高精准性。

4 结 论

面向高渗透率光伏微电网的发电功率短期预测精准度偏低难题,提出CG-DBN发电功率预测模型。为增强预测科学性与精确度,引入马尔科夫链位移时序预测法,进而对CG-DBN预测模型进行修正,建立MFM-CG-DBN发电功率短期预测模型。进一步基于晴天、雨天与多云3种天气类型,对比MFM-CG-DBN短期预测模型与CG-DBN短期预测模型的发电功率预测精准性。仿真结果表明:

1)运用马尔科夫链位移时序预测法(MFM)对CG-DBN预测模型进行修正,据此构建马尔科夫链位移时序预测法修正的短期预测模型(MFM-CG-DBN)。该模型符合高渗透率光伏微电网发电功率特征,综合MFM模型与CG-DBN模型的综合优点,较适用于解决样本数量少且随机波动性大的高渗透率光伏微电网时间序列预测问题。算例仿真结果表明,MFM-CG-DBN模型可有效提高对不同天气状况下高渗透率光伏微电网发电功率的预测精度。

2)与CG-DBN短期预测模型相比,晴天天气下,MFM-CG-DBN短期预测模型的 E_{CD} 、 E_{MT} 与 E_{MS} 值分别降低0.63%、2.49%和0.23%, R^2 则提高0.06%;多云天气下的 E_{CD} 、 E_{MT} 与 E_{MS} 值分别降低1.87%、0.71%和0.65%, R^2 提高0.05%;雨天天气下的 E_{CD} 、 E_{MT} 与 E_{MS} 值分别降低0.41%、0.73%和0.28%,而 R^2 提高0.03%。

3)从对不同天气类型的高渗透率光伏微电网发电功率预测值来看,MFM-CG-DBN短期预测模型得出的发电功率值更贴近事实。由此说明,基于MC-CG-DBN短期模型预测精度更高,这为后续高渗透率光伏发电功率预测提供重要参照。

[参考文献]

- [1] 许健,刘念,于雷,等.计及重要负荷的工业光伏微电网储能优化配置[J].电力系统保护与控制,2016,44(9):29-37.
XU J, LIU N, YU L, et al. Optimal allocation of energy storage system of PV microgrid for industries considering important load [J]. Power system protection and control, 2016, 44(9): 29-37.
- [2] 李廷钧,杜欣慧,姚宏民.计及用户评价的智能用电社区分层优化调度[J].电网技术,2018,42(11):3486-3495.
LI T J, DU X H, YAO H M. Hierarchical dispatch optimization for intelligent power community considering electricity evaluation[J]. Power system technology, 2018, 42(11): 3486-3495.
- [3] 滕陈源,丁逸超,张有兵,等.基于VMD-Informer-BiLSTM模型的超短期光伏功率预测[J].高电压技术,2023,49(7):2961-2971.
TENG C Y, DING Y C, ZHANG Y B, et al. Ultra-short-term photovoltaic power prediction based on VMD-Informer-BiLSTM model [J]. High voltage engineering, 2023, 49(7): 2961-2971.
- [4] 王涛,王旭,许野,等.计及相似日的LSTM光伏出力预测模型研究[J].太阳能学报,2023,44(8):316-323.
WANG T, WANG X, XU Y, et al. Study on LSTM photovoltaic output prediction model considering similar days [J]. Acta energiae solaris sinica, 2023, 44(8): 316-323.
- [5] 普智勇,夏攀,张璐,等.机器学习与统计方法在太阳能预报中的比较性分析[J].太阳能学报,2023,44(7):162-167.
PU Z Y, XIA P, ZHANG L, et al. Comparative analysis of machine learning and statistical methods in solar energy prediction[J]. Acta energiae solaris sinica, 2023, 44(7): 162-167.
- [6] 张程熠,唐雅洁,李永杰,等.适用于小样本的神经网络光伏预测方法[J].电力自动化设备,2017,37(1):101-106,111.
ZHANG C Y, TANG Y J, LI Y J, et al. Photovoltaic power forecast based on neural network with a small number of samples [J]. Electric power automation equipment, 2017, 37(1): 101-106, 111.
- [7] BATES J M, GRANGER C W J. The combination of forecasts [J]. Journal of the Operational Research Society, 1969, 20(4): 451-468.
- [8] 李正明,高赵亮,梁彩霞.基于FCM和CG-DBN的光伏功率短期预测[J].现代电力,2019,36(5):62-67.

- LI Z M, GAO Z L, LIANG C X. Short-term prediction of photovoltaic power based on combination of FCM and CG-DBN[J]. *Modern electric power*, 2019, 36(5): 62-67.
- [9] PROUDMAN J, REDDING S. Evolving patterns of international trade[J]. *Review of international economics*, 2000, 8(3): 373-396.
- [10] 辛欣瑶, 汪建文, 赵煜, 等. 考虑扇区划分的自然风风向建模[J]. *太阳能学报*, 2022, 43(11): 311-316.
- XIN X Y, WANG J W, ZHAO Y, et al. Wind direction modeling considering sector division [J]. *Acta energiae solaris sinica*, 2022, 43(11): 311-316.
- [11] 宋绍剑, 李博涵. 基于LSTM网络的光伏发电功率短期预测方法的研究[J]. *可再生能源*, 2021, 39(5): 594-602.
- SONG S J, LI B H. Short-term forecasting method of photovoltaic power based on LSTM[J]. *Renewable energy resources*, 2021, 39(5): 594-602.
- [12] 宋煜, 郭军红, 袁荔, 等. 基于逐步聚类分析的短期光伏发电预测方法[J]. *热能动力工程*, 2023, 38(10): 158-166.
- SONG Y, GUO J H, YUAN L, et al. Short-term photovoltaic power generation prediction method based on stepwise clustering analysis[J]. *Journal of engineering for thermal energy and power*, 2023, 38(10): 158-166.
- [13] 李斌, 张一凡, 颜世烨, 等. 基于改进极限学习机ELM的光伏发电预测方法研究[J]. *热能动力工程*, 2022, 37(10): 207-214.
- LI B, ZHANG Y F, YAN S Y, et al. Research on photovoltaic power generation prediction method based on improved extreme learning machine (ELM) [J]. *Journal of engineering for thermal energy and power*, 2022, 37(10): 207-214.
- [14] 王瑞, 闫豪, 逯静. 基于ICEEMDAN-MBWO-WKELM短期光伏功率预测[J]. *电力电子技术*, 2024, 58(2): 59-63.
- WANG R, YAN H, LU J. Short-term photovoltaic power prediction based on ICEEMDAN-MBWO-WKELM [J]. *Power electronics*, 2024, 58(2): 59-63.
- [15] 吕玉坤, 赵润一, 周庆文, 等. 环境因素对光伏组件的温度及输出特性影响研究[J]. *太阳能学报*, 2024, 45(11): 194-203.
- LYU Y K, ZHAO R Y, ZHOU Q W, et al. Investigation on influence of environmental factors on temperature and output characteristics of solar PV modules [J]. *Acta energiae solaris sinica*, 2024, 45(11): 194-203.
- [16] 师浩琪, 郭力, 刘一欣, 等. 基于多源气象预报总辐照度修正的光伏功率短期预测[J]. *电力自动化设备*, 2022, 42(3): 104-112.
- SHI H Q, GUO L, LIU Y X, et al. Short-term forecasting of photovoltaic power based on total irradiance correction of multi-source meteorological forecast [J]. *Electric power automation equipment*, 2022, 42(3): 104-112.
- [17] 郭斯琦, 楼劲, 郑凌蔚. 考虑热网特性的综合能源系统混合时间尺度调度方法[J]. *电力建设*, 2024, 45(12): 16-26.
- GUO S Q, LOU J, ZHENG L W. Hybrid time scale scheduling method for integrated energy systems considering the characteristics of heating networks [J]. *Electric power construction*, 2024, 45(12): 16-26.
- [18] 欧阳卫年, 赵紫昱, 陈渊睿. 自样本特征构造的1DCNN-BiLSTM网侧光伏功率预测[J]. *电力系统及其自动化学报*, 2024, 36(3): 151-158.
- OUYANG W N, ZHAO Z Y, CHEN Y R. 1DCNN-BiLSTM method of grid-side photovoltaic power prediction with self-sampled feature construction [J]. *Proceedings of the CSU-EPSA*, 2024, 36(3): 151-158.
- [19] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets [J]. *Neural computation*, 2006, 18(7): 1527-1554.
- [20] 刘友波, 吴浩, 刘挺坚, 等. 集成经验模态分解与深度学习的用户侧净负荷预测算法[J]. *电力系统自动化*, 2021, 45(24): 57-64.
- LIU Y B, WU H, LIU T J, et al. User-side net load forecasting method integrating empirical mode decomposition and deep learning [J]. *Automation of electric power systems*, 2021, 45(24): 57-64.
- [21] 韩冰, 柳师捷, 陈宇航. 基于EEMD和EIKF的船舶轴系状态趋势预测研究[J]. *中国航海*, 2023, 46(4): 141-146.
- HAN B, LIU S J, CHEN Y H. Trend prediction of the operating status of ship engine room equipment based on EEMD and EIKF [J]. *Navigation of China*, 2023, 46(4): 141-146.
- [22] 邢志伟, 刘鹏, 李彪, 等. 多马尔可夫链协同的航班客舱保障过程预测[J]. *计算机工程与设计*, 2024, 45(3): 948-955.
- XING Z W, LIU P, LI B, et al. Prediction for flight cabin service process based on synergy of multi-Markov chains [J]. *Computer engineering and design*, 2024, 45(3): 948-955.
- [23] 赵洪山, 孙承妍, 温开云. 基于多气象类型加权和改进高斯混合模型的光伏出力超短期概率预测[J]. *太阳能学报*, 2024, 45(7): 567-576.
- ZHAO H S, SUN C Y, WEN K Y. Ultra-short-term probability prediction of PV output based on multi-weather-type-weighted and improved Gaussian mixture model [J]. *Acta energiae solaris sinica*, 2024, 45(7): 567-576.

- [24] 吴慧军, 郭超雨, 苏承国, 等. 基于 EEMD-GRU-MC 的短期风功率组合预测方法[J]. 南方电网技术, 2023, 17(2): 66-73.
WU H J, GUO C Y, SU C G, et al. Combined prediction method for short-term wind power based on EEMD-GRU-MC[J]. Southern power system technology, 2023, 17(2): 66-73.
- [25] 鞠泽慧. 光伏微电网发电预测及优化调度研究[D]. 南昌: 南昌大学, 2022.
JU Z H. Research on power generation prediction and optimal scheduling of photovoltaic microgrid [D]. Nanchang: Nanchang University, 2022.

SHORT TERM PREDICTION OF HIGH PENETRATION PHOTOVOLTAIC MICROGRID POWER GENERATION BASED ON MFM-CG-DBN MODEL

Xu Xiaoming¹, Wang Zhanhai²

(1. School of Intelligent Manufacturing, Xinxiang Vocational and Technical College, Xinxiang 453006, China;
2. School of Electronic and Information Engineering, Hengshui University, Hengshui 053000, China)

Abstract: To improve the accuracy of power generation prediction in high penetration photovoltaic microgrids, this paper proposes an improved Markov chain displacement time series prediction method (MFM) to optimize the problems of insufficient feature extraction and inaccurate prediction in the conjugate gradient method (CG) - deep belief network (DBN) combined prediction model (CG-DBN). Firstly, using Pearson correlation coefficient to analyze the influencing factors of high penetration photovoltaic microgrid power generation; Secondly, taking advantage of the inefficiency of Markov chain displacement time series prediction method, the residual correction process is applied to the CG-DBN prediction model to construct a short-term prediction model for the power generation of MFM-CG-DBN high penetration photovoltaic microgrids; Finally, the MFM-CG-DBN short-term prediction model is used to simulate the power generation data of high penetration photovoltaic microgrids under three types of weather conditions: sunny, cloudy, and rainy. The simulation results show that the proposed short-term prediction model has higher prediction accuracy than the traditional CG-DBN short-term prediction model, and can meet the demand for high penetration photovoltaic microgrid power generation prediction.

Keywords: Markov chains; microgrids; photovoltaic power; high permeability; MFM-CG-DBN