

面向模型预测控制的风电机组深度 Koopman全局线性建模方法*

田润泽^{1,2,3} 寇鹏^{1,2,3} 武义琨^{1,2,3} 张智豪^{1,2,3} 张远航^{1,2,3} 王若涛⁴ 郝守
礼⁴ 梁得亮^{1,2,3}

(1. 西安交通大学电气工程学院, 710049, 西安; 2. 西安交通大学陕西省智能电网重点实验室, 710049, 西安; 3. 西安交通大学电工材料电气绝缘全国重点实验室, 710049, 西安;
4. 北京京能国际控股有限公司北方分公司, 010000, 呼和浩特)

摘要: 针对风电机组复杂的非线性动态特性阻碍了面向模型预测控制的机组建模, 以及现有非线性和局部线性建模方法在模型复杂度和精度方面存在局限性等问题, 提出了一种风电机组全局线性建模方法。首先, 基于Koopman算子理论和深度学习技术, 设计了状态空间映射神经网络; 随后, 建立了该网络的训练策略, 其特点在于包含一个基于Frobenius范数的正则化项, 用以提升所得模型的长期预测精度; 最后, 通过数据驱动的方式训练所提网络, 从而建立起风电机组的高维全局线性动态模型。仿真验证结果表明: 所提方法下, 风轮转速和桨距角的预测误差分别为0.869%和0.026%, 远低于三种对比方法; 与局部线性动态模型相比, 基于所建高维全局线性动态模型的风电场MPC策略使机组风轮转速跟踪误差和越限程度分别降低了92.58%和95.85%。研究成果可为面向模型预测控制的风电机组动态建模提供理论参考。

关键词: 风电机组; Koopman算子理论; 深度学习; 全局线性建模; 模型预测控制

中图分类号: TM614 **文献标志码:** AA

文章编号: 0253-987X(XXXX)XX-0001-19

Model Predictive Control-Oriented Deep Koopman Global Linear Modeling Method for Wind Turbine

TIAN Runze^{1,2,3}, KOU Peng^{1,2,3}, WU Yikun^{1,2,3}, ZHANG Zhihao^{1,2,3}, ZHANG Yuanhang^{1,2,3},
WANG Ruotao⁴, HAO Shouli⁴, LIANG Deliang^{1,2,3}

(1. School of Electrical Engineering, Xi'an Jiaotong University, Xi'an 710049, China;
2. Shaanxi Key Laboratory of Smart Grid, Xi'an Jiaotong University, Xi'an 710049, China;
3. State Key Laboratory of Electrical Insulation and Power Equipment, Xi'an Jiaotong University, Xi'an 710049, China;
4. Beijing Jingneng International Holding Co. Ltd. Northern Branch, Hohhot 010000, China)

Abstract: To address the challenges posed by the complex nonlinear dynamics of wind turbines, which hinder the model predictive control-oriented wind turbine modeling, as well as the limitations of existing nonlinear and local linear modeling methods in model complexity and accuracy, a global linear

收稿日期: 2025-XX-XX。作者简介: 田润泽(1998-), 男, 博士生; 寇鹏(通信作者), 男, 教授, 博士生导师。基金项目: 国家自然科学基金资助项目(52077165)。

wind turbine modeling method is proposed. First, based on the Koopman operator theory and deep learning techniques, a state-space mapping neural network is designed. Subsequently, a training strategy is developed for this neural network. The key feature of this strategy is that a Frobenius norm-based regularization term is incorporated to enhance the long-term accuracy of the established model. Finally, by training the proposed neural network in a data-driven manner, the high-dimensional global linear wind turbine dynamic model is established. Simulation results demonstrate that, with the proposed method, the prediction errors of rotor speed and pitch angle are, respectively, 0.869% and 0.026%, which is significantly lower than the three comparative methods. Furthermore, compared to the local linear model, the scheme based on the established high-dimensional global linear model reduces the rotor speed tracking error and overshoot by 92.58% and 95.85%, respectively. This study provides a theoretical reference for model predictive control-oriented wind turbine modeling.

Keywords: wind turbine; Koopman operator theory; deep learning; global linear modeling; model predictive control

风力发电作为发展最快、最具竞争力的新能源发电技术之一,其装机容量逐年上升^[1]。然而,由于风电具有随机性和波动性特征,大规模风电接入后,电力系统的安全稳定运行面临严峻挑战^[2]。在风电场层面,构建高效、可靠的模型预测控制(model predictive control, MPC)策略,实现风电场的有功功率控制(active power control, APC)以及电力系统频率支撑等目标,是应对这一挑战的重要途径^[3]。

而构建上述控制策略的一个先决条件,是建立能够准确刻画风电机组动态,且能够适配MPC计算复杂度的风电机组动态模型。该模型的纳入,将使风电场MPC策略能够充分考虑其内部各个机组的运行状态差异以及动态特性,从而达成更好的控制效果^[4]。然而,风电机组动态具有复杂的非线性特征,为构建这一模型带来了阻碍。

在现有相关研究中,风电机组的动

态建模思路主要可分为两类。第一类为非线性建模思路,例如在文献[4]~[7]中,建立了机组的非线性动态机理模型。而在文献[8]和[9]中,则采用数据驱动的方式,利用神经网络开展了风电机组的非线性建模研究。第二类为局部线性化建模思路^[10-14],此类模型的建立通常包含两个步骤:首先,根据风电机组的物理机理,构建其非线性模型。随后,在机组的稳态工作点附近,对所建模型进行一阶泰勒展开,从而得到相应的局部线性模型。

综合来看,非线性模型虽相较局部线性模型具有更高的精度,但非线性特性使其无法适用于构建易于在线求解的线性MPC策略。因此,文献[4]~[9]中构建的风电场控制策略,均为非线性MPC策略,其所对应的优化问题,也是难以在线求解的非凸优化问题,这限制了其在工程中的应用。而对于局部线性模型^[10-14],其虽能够应用于构建线性

MPC策略,但此类模型仅在特定工作点附近准确。在实时控制应用中,模型精度的不足可能引发模型失配问题。部分文献尝试了在多个稳态工作点处分别构建局部线性模型,并建立多个对应MPC控制器,来试图解决该问题^[13-14],但这一做法可能会导致实时控制过程中控制器的频繁切换,从而给控制系统的整体稳定性带来隐患。

由以上讨论可知,在风电场的模型预测控制研究中,如何建立兼具较高精度和较低复杂度的风电机组全局线性动态模型,是一个亟待解决的关键问题。一方面,全局线性动态模型的线性特性,将使其能够应用于构建易于在线求解的线性MPC策略;另一方面,全局线性动态模型的全局性,能够避免因工作点变化所引发的模型失配,以及多模型MPC所伴随的控制器频繁切换问题。

Koopman算子理论^[15]为构建这一全局线性动态模型提供了基本的理论框架。该理论表明,可将非线性系统所固有的非线性动态,通过状态空间的升维映射,转化为高维空间内的全局线性动态,从而构建该非线性系统的高维全局线性动态模型。然而遗憾的是,目前基于Koopman算子理论开展的风电机组全局线性建模研究尚十分有限,文献[16]和[17]是为数不多的研究报道。这两项研究均以Koopman算子理论为依据,采用扩展动态模态分解(extended dynamic mode decomposition, EDMD)算法,构建了风电机组的全局线性动态模

型。该方法是风电机组Koopman高维全局线性动态建模研究的先驱探索,但因其需要人工选取升维映射函数集,故而难以避免主观性和经验性。如选取的升维映射函数集不合适,将大幅度降低所建立模型的准确性。

为解决上述问题,本文提出了一种基于Koopman算子理论和深度学习技术的风电机组全局线性建模方法。首先,基于Koopman算子理论,设计了状态空间映射神经网络。其由实现风电机组状态空间升维映射的升维模块,以及实现风电机组高维状态线性递推的递推模块构成。随后,设计训练策略,对上述两类模块进行统一训练,由此得到升维映射函数集,以及与之相对应的风电机组高维全局线性动态模型。特别地,在训练过程中,设计了一种基于Frobenius范数的正则化项,用于提升所得模型的长期预测精度。所提方法的主要特点在于:一方面,以Koopman算子理论为基础,保证了所得模型的全局线性特征;另一方面,利用神经网络的非线性映射能力,以纯数据驱动的方式表征机组状态空间的升维映射,从而避免了人工选择升维映射函数集时的主观性和经验性。

1 风电机组非线性动态建模

通过捕获风能,风电机组获取的机械转矩 T_m 为

$$T_m = [0.5\pi\rho R^2 v^3 C_p(\lambda, \beta)] / \omega_r \quad (1)$$

式中: ρ 为空气密度; R 为风电机组风

轮半径； v 为有效风速； β 为桨距角； ω_r 为风轮转速； λ 为叶尖速比， $\lambda = \omega_r R / v$ ； C_p 为风能利用系数，其为 λ 和 β 的非线性函数，可将其表示为

$$C_p(\lambda, \beta) = c_1 \left(c_2 \left(\frac{1}{\lambda + 0.08\beta} - \frac{0.035}{\beta^3 + 1} \right) - c_3\beta - c_4\beta^{c_5} - c_6 \right) \times \exp \left(-c_7 \left(\frac{1}{\lambda + 0.08\beta} - \frac{0.035}{\beta^3 + 1} \right) \right) \quad (2)$$

式中： $c_1 \sim c_7$ 为常数，其具体取值与机组型号有关。

捕获的风能通过传动链输送至发电机，考虑传动链轴系的柔性特征，可将其动态表示为^[18]

$$\begin{cases} J_r \dot{\omega}_r = T_m - K_s \psi - K_v \dot{\psi} \\ J_g \dot{\omega}_g = (K_s \psi + K_v \dot{\psi}) / \eta_g - T_g \\ \dot{\psi} = \omega_r - \omega_g / \eta_g \end{cases} \quad (3)$$

式中： η_g 为齿轮箱传动比； T_g 为发电机转矩； ω_g 为发电机转速； J_r 为风轮的转动惯量； J_g 为发电机的转动惯量； K_s 为传动链轴系的刚度系数； K_v 为传动链轴系的阻尼系数； ψ 为传动链轴系的角位移。

由于风电机组中电力电子变流器的响应速度远快于其机械部分的响应速度，可近似认为风电机组输出的有功功率等于其参考值 P_c^{ref} 。因此，机组的发电机转矩可以表示为

$$T_g = P_c^{\text{ref}} / \omega_r \quad (4)$$

机组的桨距角动态可表示为以下一阶系统^[19]：

$$\dot{\beta} = \frac{1}{1 + sT_p} \beta^{\text{ref}} \quad (5)$$

式中： T_p 为执行机构时间常数； β^{ref} 为桨距角参考值。

2 基于Koopman算子理论的风电机组全局线性建模问题描述

根据第1节中的风电机组动态建模，机组动态主要包括传动链轴系动态和桨距角动态。对于式(3)所示传动链轴系动态，其状态量分别为风轮转速 ω_r 、发电机转速 ω_g 和传动链轴系的角位移 ψ 。同时，根据式(1)、(3)和(4)，该动态的输入量包含有效风速 v 和有功功率参考值 P_c^{ref} 。对于式(5)所示桨距角动态，其状态量为桨距角 β ，输入量为桨距角参考值 β^{ref} 。

综上所述，从构建风电场MPC策略的角度出发，可将风电机组的动态概括为以下状态空间模型：

$$[\bar{\mathbf{x}}_{k+1}] = \mathbf{f}(\bar{\mathbf{x}}_k, \bar{\mathbf{u}}_k), \quad \bar{\mathbf{x}}_k = [\omega_{r,k}, \omega_{g,k}, \psi_k, \beta_k]^T, \quad (6)$$

$$\bar{\mathbf{u}}_k = [P_{c,k}^{\text{ref}}, \beta_k^{\text{ref}}, v_k]^T$$

式中： $\bar{\mathbf{x}}$ 和 $\bar{\mathbf{u}}$ 分别表示风电机组原始空间内的状态量和输入量； $\mathbf{f}$ 为状态转移函数；添加下标 k 表示对应变量在第 k 时刻的取值。由式(1)~(3)可知，该模型为非线性动态模型，其非线性主要源于风电机组传动链动态和风能利用系数的复杂非线性特征。因此，该模型无法用于构建线性MPC策略。

Koopman算子理论^[15]为解决这一问题提供了基本的理论框架。根据该理论

及其在控制领域的拓展^[20],可以通过一个升维映射函数集,将非线性系统在原始空间内所固有的非线性动态,升维映射为高维空间内的全局线性动态,从而建立起该非线性系统的全局线性动态模型。在利用该理论构建风电机组高维全局线性动态模型时,这一过程可表示为

$$\mathbf{z}_k = \mathbf{g}^*(\bar{\mathbf{x}}_k), \mathbf{z}_{k+1} = \mathbf{A}^* \mathbf{z}_k + \mathbf{B}^* \bar{\mathbf{u}}_k \quad (7)$$

式中: $\mathbf{g}^*$ 表示升维映射函数集,该函数集将风电机组的状态量从原始空间映射至高维空间; $\mathbf{z} \in \mathbb{R}^N$ 表示高维空间内风电机组的状态量,即风电机组升维状态; $\mathbf{A}^* \in \mathbb{R}^{N \times N}$ 和 $\mathbf{B}^* \in \mathbb{R}^{N \times m}$ 分别表示风电机组高维全局线性动态模型的状态转移矩阵和输入矩阵。

尽管 Koopman 算子理论为构建风电机组全局线性动态模型提供了理论框架,但要最终实现这一目标,还需要设计一种建模方法来搜寻 $\mathbf{g}^*$ 、 $\mathbf{A}^*$ 以及 $\mathbf{B}^*$ 。如引言所述,文献[16-17]利用 EDMD 算法为该搜寻提供了一种可行方案。然而,该方案需要人工选取升维映射函数集,这增加了建模的主观性与经验性,从而限制了模型精度。为此,本文在 Koopman 算子理论的框架下,利用深度学习技术,提出了一种风电机组全局线性建模方法。

3 风电机组深度 Koopman 全局线性建模方法

本节提出了一种基于 Koopman 算子理论和深度学习技术的风电机组全局线性建模方法。首先,基于 Koopman

算子理论,同时参考原始空间内风电机组的非线性动态,设计了状态空间映射神经网络。随后,提出了该神经网络的训练策略。特别地,在该训练策略中,设计了一种基于 Frobenius 范数的正则化项,用于保证所得模型的长期预测精度。

3.1 状态空间映射神经网络结构

本文所设计的状态空间映射神经网络的总体结构如图1所示。其主要包含升维模块和递推模块这两类模块。

3.1.1 升维模块

升维模块通过表征风电机组原始状态和高维状态间的升维映射关系,实现对升维映射函数集的拟合。其具体设计流程如下:

首先,需要明确该模块的输入。根据 Koopman 算子理论,该输入应该包含原始空间内风电机组的状态 $\bar{\mathbf{x}}$ 。此外,如第2节所述,风电机组动态的非线性特征,除了来自于非线性的传动链动态外,还来自风能利用系数 C_p 这一非线性函数。该函数的自变量除了包含已纳入升维模块输入的风轮转速 ω_r 和桨距角 β 外,还包含风轮处的有效风速 v 。因此,为了在状态升维过程中充分考虑风电机组动态的非线性特征,将风轮处的有效风速 v 也添加至升维模块的输入。至此,升维模块的输入 $\mathbf{x}_k$ 可表示为

$$\mathbf{x}_k = [\bar{\mathbf{x}}_k, v_k] = [\omega_{r,k}, \omega_{g,k}, \psi_k, \beta_k, v_k]^T \quad (8)$$

随后,对升维模块的结构进行设

计。为避免人工选择升维映射函数集的主观性和经验性,本文选取具有万能近似能力的神经网络作为升维模块的主要组成部分,即图1中的升维网络。进一步地,选取多层感知机(multilayer perceptron, MLP)作为升维网络中所采

用的具体神经网络框架。其原因在于,MLP的输入与输出特征均为向量结构,使其能够表征风电机组原始状态向量和高维状态向量间的复杂非线性映射关系。同时MLP具有较低的计算复杂度。至此,可将升维网络具体表示为




图1 状态空间映射神经网络

Fig. 1 State-space mapping neural network

$$\begin{aligned} \varphi_k &= \mathbf{g}_{\text{MLP}}(\mathbf{x}_k; \boldsymbol{\theta}) \\ \varphi_k &= [\varphi_{1,k}, \varphi_{2,k}, \varphi_{3,k}, \dots, \varphi_{M,k}]^T \end{aligned} \quad (9)$$

式中: $\mathbf{g}_{\text{MLP}}$ 表示升维网络的正向运算过程; $\boldsymbol{\theta}$ 表示升维网络中的可训练参数; $\varphi \in \mathbb{R}^M$ 表示基于升维网络得到的 M 维升维状态, 该状态是风电机组升维状态的主要组成部分; $\varphi_i, i \in [1, M]$ 表示 φ 中的元素。

若风电机组的升维状态均由升维网络以“黑箱”映射的方式生成, 所得机组全局线性动态模型将缺乏物理可解释性, 从而难以用于构建风电场 MPC 策略。参考现有研究中解决此问题的常见做法^[16-17,20], 除升维网络外, 本文还在

升维模块中引入了两个恒等映射机制, 将风轮转速和桨距角这两个风电机组的被控状态直接纳入升维状态中。最终, 可将升维模块表示为

$$\mathbf{z}_k = \mathbf{g}(\mathbf{x}_k; \boldsymbol{\theta}) = [\omega_{t,k}, \beta_k, \mathbf{g}_{\text{MLP}}(\mathbf{x}_k; \boldsymbol{\theta})]^T \quad (10)$$

式中: $\mathbf{g}$ 表示升维模块的运算过程; $\mathbf{z}_k \in \mathbb{R}^N$ 表示由升维模块得到的风电机组 N 维升维状态。

根据本节内容可知, 所提状态空间映射神经网络是参考式(1)~(5)所示水平轴风电机组的通用动态物理机理设计的。因此, 其适用于各型号水平轴风电机组的动态建模。

3.1.2 递推模块

递推模块通过表征风电机组升维状态在高维空间内的线性递推,实现对机组高维全局线性动态模型的拟合。如图1所示,所提状态空间映射神经网络中包含 T 个递推模块,可具体表示为

$$\begin{cases} \hat{\mathbf{z}}_{k+j} = \mathbf{A}\mathbf{z}_{k+j-1} + \mathbf{B}\mathbf{u}_{k+j-1}, j=1 \\ \hat{\mathbf{z}}_{k+j} = \mathbf{A}\hat{\mathbf{z}}_{k+j-1} + \mathbf{B}\mathbf{u}_{k+j-1}, j=2, \dots, T \end{cases} \quad (11)$$

式中: $\hat{\mathbf{z}}$ 为递推模块对风电机组升维状态的预测值; $\mathbf{A} \in \mathbb{R}^{N \times N}$ 和 $\mathbf{B} \in \mathbb{R}^{N \times 4}$ 为递推模块中的待训练参数,分别用于拟合机组高维全局线性动态模型中的状态转移矩阵和输入矩阵。 $\mathbf{u}_k$ 为第 k 时刻机组高维全局线性动态模型的输入,可具体表示为

$$\mathbf{u}_k = [P_{c,k}^{\text{ref}}, \beta_k^{\text{ref}}, v_k, v_{k+1}] \quad (12)$$

可以注意到,相较于式(6)所示风电机组非线性动态模型的输入,式(12)中额外包含了 $k+1$ 时刻的有效风速 v_{k+1} 。其作用在于,提供准确预测 $\hat{\mathbf{z}}_{k+1}$ 所需的 $k+1$ 时刻的有效风速信息。

最后,综合3.1.1和3.1.2节可知,

所提状态空间映射神经网络具有简单的网络结构。具体而言,该网络包含三个待训练部分,即升维网络、待训练矩阵 $\mathbf{A}$ 和待训练矩阵 $\mathbf{B}$ 。其中,升维网络采用具有低计算复杂度的MLP构建,而待训练矩阵 $\mathbf{A}$ 和 $\mathbf{B}$ 则可视为基础的全连接层。该结构能够有效降低利用所提网络构建高维模型时的计算负担。

3.2 状态空间映射神经网络训练策略

状态空间映射神经网络的训练策略如图2所示。在该训练策略中,损失函数由两部分构成。其中,第一部分以数据驱动的方式,保证风电机组高维全局线性动态模型在 T 步时域迭代中的精度,可将其具体表示为

$$L_{\text{pre}} = \sum_{j=1}^T l_j, l_j = \frac{1}{2} \cdot (\hat{\mathbf{z}}_{k+j} - \mathbf{z}_{k+j})^2 \quad (13)$$

式中: L_{pre} 为状态空间映射神经网络损失函数的第一部分; l_j 为模型在第 j 步预测中的预测误差。




图2 状态空间映射神经网络的训练策略

Fig. 2 Training strategy of the state-space mapping neural network

此外, 根据文献[21], 在利用 Koopman 算子理论构建离散高维全局线性动态模型时, 可通过约束该模型的状态转移矩阵, 使其谱半径小于1, 来提升该模型的数值稳定性。数值稳定性的提升, 能够有效降低模型在长时间跨度迭代过程中的累积误差, 从而提升其长期预测精度^[21]。对于所建风电机组高维全局线性动态模型而言, 长期预测精度是指模型通过滚动预测的方式, 对未来长时间跨度的机组状态进行预测时的预测准确性。

实现上述约束的直接做法为, 将损失函数的第二部分 L_{sta} 设计为 $L_{\text{sta}} = \max(0, \rho(\mathbf{A}) - 1)$ 。其中 $\rho(\mathbf{A})$ 表示矩阵 $\mathbf{A}$ 的谱半径。然而, 由于 $\mathbf{A}$ 与 $\rho(\mathbf{A})$ 之间的函数关系在光滑性上无法得到严格保障, 所以这一设计将导致训练过程在计算梯度 $\nabla_{\mathbf{A}} L_{\text{sta}} = \nabla_{\mathbf{A}} \rho(\mathbf{A})$ 时, 出现严重的数值问题, 从而使状态空间映射神经网络的训练无法顺利进行。

为解决该问题, 本文利用“矩阵谱半径不大于其 Frobenius 范数”的性质, 得到了 $\rho(\mathbf{A})$ 的上界, 即

$$\rho(\mathbf{A}) \leq \|\mathbf{A}\|_{\text{F}} = \sqrt{\sum_{i=1}^N \sum_{j=1}^N a_{i,j}^2} \quad (14)$$

式中: $\|\mathbf{A}\|_{\text{F}}$ 表示矩阵 $\mathbf{A}$ 的 Frobenius 范数; a 为矩阵 $\mathbf{A}$ 中的元素。 $\mathbf{A}$ 与 $\|\mathbf{A}\|_{\text{F}}$ 间的函数关系, 除在 $\mathbf{A}$ 为零矩阵处外, 在其余部分均严格光滑。基于该性质, 本文设计了训练策略中损失函数的第二部分, 即

$$L_{\text{sta}} = \max(0, \|\mathbf{A}\|_{\text{F}} - 1) \quad (15)$$

值得注意的是, $\mathbf{A}$ 与 $\|\mathbf{A}\|_{\text{F}}$ 间的函数关系在 $\mathbf{A}$ 为零矩阵处的不光滑性不会为训练带来数值问题。其原因在于, 当 $\mathbf{A}$ 为零矩阵时, $\nabla_{\mathbf{A}} L_{\text{sta}} = \nabla_{\mathbf{A}} 0 = 0$ 。

至此, 状态空间映射神经网络的训练可表示为以下优化问题:

$$\min_{\theta, \mathbf{A}, \mathbf{B}} L_{\text{pre}} + L_{\text{sta}} \quad (16)$$

该优化问题可以利用 Adam 算法^[22] 进行迭代求解, 从而构建起风电机组升维映射函数集(17), 及其对应的高维全局线性动态模型(18)。

$$\mathbf{z}_k = \mathbf{g}^*(\mathbf{x}_k) = \mathbf{g}(\mathbf{x}_k; \theta^*) = [\omega_{r,k} \beta_k \mathbf{g}_{\text{MLP}}(\mathbf{x}_k; \theta^*)] \quad (17)$$

$$\mathbf{z}_{k+1} = \mathbf{A}^* \mathbf{z}_k + \mathbf{B}^* \mathbf{u}_k \quad (18)$$

式中: θ^* 、 $\mathbf{A}^*$ 、 $\mathbf{B}^*$ 分别为状态空间映射神经网络中待训练参数 θ 、 $\mathbf{A}$ 、 $\mathbf{B}$ 的训练结果。

结合式(17)和(18)可知, 所得机组高维全局线性动态模型能够以线性的方式刻画机组风轮转速和桨距角的动态。因此, 该模型可直接在风电场 MPC 策略中, 为这两个状态的精细化控制提供预测模型支撑, 无需开展额外的状态筛选或逆映射。

值得注意的是, 在基于模型(18)构建风电场 MPC 策略时, 可采用“紧凑”形式, 从而有效避免模型高维特性导致的 MPC 策略计算复杂度的增加。对于该结论, 文献[20]给出了详细证明。

同时, 根据 Koopman 算子理论, 准确无误地实现非线性动态的全局线性表达, 往往需要线性模型的维度达到无限维。然而, 出于实用性考虑, 所提方

法构建的模型为该无限维模型的高维近似,这使得所提方法存在理论建模误差。

3.3 风电机组高维全局线性动态模型的准确性

首先,利用丹麦奥尔堡大学开发的 SimWindFa-

rm 工具箱^[23],搭建起 NREL 5 MW 风电机组仿真平台^[24],该机组的具体参数如表 1 所示。随后,利用从位于锡林郭勒的风电场获取的风速数据,通过该仿真平台,收集机组运行数据,最终构建起机组运行数据集。该数据集中包含 21000 个时刻的机组运行数据。其中,参考文献[25],本研究将相邻两时刻的时间间隔设置为 0.1 s。在该时间间隔下,所建风电机组高维全局线性动态模型能够有效捕捉机组传动链轴系和桨距角执行机构的暂态响应过程。进一步地,将上述运行数据中的前 16000 个时刻为训练集,用于训练状态空间映射神经网络,从而建立风电机组高维全局线性动态模型。后 5000 个时刻作为测试集,用于测试所得模型的精度。此外,采用网格搜索法确定了状态空间映射神经网络的超参数,如表 2 所示。

为了验证本文所提基于深度学习的风电机组 Koopman 全局线性建模方法的先进性,本算例分析中将其与基于 EDMD 算法的 Koopman 全局线性建模方法进行对比。根据人工选取升维映射函数集时采用的方式,将对比方法进一

步划分为以下两类:第一类方法为传统 EDMD 方法,其直接利用高斯基函数、多调和基函数等常见基函数构成升维映射函数集;第二类为文献[16]和[17]中提出的 SDMD 方法。相较于传统 EDMD 方法,该方法在人工选择升维映射函数集时参考了机组动态机理,从而在一定程度上降低了该选择过程的主观性与经验性。

随后,在测试集上开展多组预测时域为 60 s,即 600 步的风电机组风轮转速和桨距角预测,来验证各个建模方法下,风电机组高维全局线性动态模型的精度。该预测的具体方式为,给定第 0 时刻的升维模块输入 $\mathbf{x}_0$,以及第 0 至 599 时刻的高维全局线性动态模型输入 $\{\mathbf{u}_k | k = [0, 599]\}$,利用该模型,以滚动预测的方式,对第 1 至 600 时刻的风电机组转速和桨距角进行预测。其中,选择风轮转速和桨距角作为预测对象的原因在于:风电场 MPC 控制器需要对这两个状态量进行控制和约束,以保障机组运行安全、提升机组动态性能。

本文选取平均绝对百分比误差 (mean absolute percentage error, MAPE) 来量化模型的预测精度。表 3 中列出了各方法所建模型在测试集上的 MAPE 均值 μ 和标准差 σ 。表中,传统 EDMD-G 和传统 EDMD-P 方法分别表示由高斯基函数和多调和基函数构成升维映射函数集的 EDMD 方法; r 和 p 分别表示风轮转速预测和桨距角预测的 MAPE。

根据表 3,在所提方法下, $\mu(r)$ 和 μ

(p)分别仅为0.869%和0.026%，显著低于对比方法。这表明所提方法构建的风电机高维全局线性动态模型具有更高的风轮转速和桨距角预测精度。同时，所提方法下的 $\sigma(r)$ 和 $\sigma(p)$ 也明显更小。这表明所提方法构建的模型对机组运行工况更具泛化能力。所提方法具有上述优势的主要原因在于，其能够自动拟合并优化风电机组的升维映射函数集，从而避免了人工选择该函数集时的主观性与经验性。

表1 NREL 5MW 风电机组参数

Table 1 Parameters of NREL 5MW wind turbine

参数	数值
齿轮箱传动比 η_g	97
发电机转动惯量 J_g ($\text{kg}\cdot\text{m}^2$)	534.116
风轮转动惯量 J_r ($\text{kg}\cdot\text{m}^2$)	35444067
传动链轴系刚度系数 K_s	867637000
传动链轴系阻尼系数 K_v	6215000
空气密度 ρ (kg/m^3)	1.2231
风轮半径 R (m)	63
桨距角执行机构时间常数 T_p	0.1
桨距角最大值 $\beta_{\max}$ ($^\circ$)	90
桨距角最小值 $\beta_{\min}$ ($^\circ$)	0
额定有功功率 (MW)	5
切入风轮转速 $\omega_{r,ci}$ (rad/s)	0.7226
额定风轮转速 $\omega_{r,rated}$ (rad/s)	1.2671

对于SDMD方法，虽然其通过参考风电机组的动态特性，在一定程度上降低了人工选取升维映射函数集时的主观性与经验性，从而在建模精度和泛化性方面优于传统EDMD方法。但是，该方法仍未摆脱对人工选取升维映射函数集的依赖，从而限制了其性能的进一

步提升。

表2 状态空间映射神经网络的超参数

Table 2 Hyperparameters of the state-space mapping neural network

超参数	数值
升维网络层数	5
升维网络输入层神经元数	5
升维网络隐层神经元数	64
升维网络输出层神经元数	64
递推模块数	20
可训练矩阵 A 维度	66×66
可训练矩阵 B 维度	66×4
学习率	$1\text{e-}4$
批量大小	256

表3 风电机组状态预测结果

Table 3 Wind turbine state prediction results

方法	$\mu(r)/\%$	$\sigma(r)/\%$	$\mu(p)/\%$	$\sigma(p)/\%$
所提方法	0.869	0.175	0.026	0.003
SDMD	3.043	1.371	0.086	0.016
传统EDMD-G	6.310	2.033	0.068	0.014
传统EDMD-P	5.704	2.182	0.070	0.014


值得注意的是，根据表3中的预测结果，在各建模方法下，模型对桨距角的预测误差均显著低于对风轮转速的预测误差。其主要原因在于：桨距角的动态较为简单，可将其视为线性动态；而风轮转速的动态则具有复杂的非线性特征。

为直观展示各方法所建模型的风轮转速预测精度，在图3(a)和图3(b)内，分别绘制了某一组风轮转速预测的结果和误差。其中，图3(b)中预测误差的计算公式为 $|\hat{\omega}_r - \omega_r|$ ， $\hat{\omega}_r$ 为风轮转速的预


测值。

根据图3(a),整体来看,相较于其余三种方法,所提方法下风轮转速的预测值曲线与真实值曲线的贴合程度最高。而根据图3(b),所提方法下风轮转速的预测误差水平最低。这一结果直观体现了所提方法在建模精度方面的优势。此外,在预测时域为0至10 s时,所提方法构建的模型展现出极低的预测误差。由于该时域范围覆盖了大多数风电场MPC策略的预测时域,这一结果体现了所建模型在主流风电场MPC策

略中的应用潜力。此外,如图3(a)所示,在预测时域为50至60 s,即对应500步至600步的滚动预测时,三种对比方法下风轮转速的预测值与真实值间已出现较大偏差,而所提方法给出的预测值仍能较好地贴合真实值。同时,根据图3(b),在该预测时域区间内,所提方法的风轮转速预测误差水平显著低于对比方法。这表明,所提方法在模型长期预测精度方面也具有明显优势,能够更好地满足长预测时域风电场MPC策略的需求。



(a) 风轮转速预测结果



(b) 风轮转速预测误差

图3 某一组风轮转速预测的结果及误差

Fig. 3 Results and errors in a certain set of rotor speed predictions

此外,在实际的工程应用中,风速误差是不可避免的。因此,需要分析风速误差对模型精度的影响。在离线训练状态空间映射神经网络时,可以利用经

验模态分解和奇异谱分析等技术提取并去除历史风速序列中的噪声成分^[26-27],从而大幅降低该风速误差对训练的影响。然而,当风电场MPC策略利用机

组高维全局线性动态模型进行在线控制时,难以实时消除风速误差。该误差主要会对模型的风轮转速预测精度产生影响。为此,本文在风速误差范围[0.1 m/

s, 1.0 m/s]内均匀选取 10 个误差等级,对各方法所建模型的风轮转速预测精度展开验证,结果如图 4 所示。




图 4 风速误差下不同方法所建模型的风轮转速预测误差

Fig. 4 Prediction errors of models established by different methods under wind speed errors

根据图 4,各个方法下,模型的风轮转速预测误差均随风速误差的增长呈上升趋势。尽管如此,在各风速误差等级下,所提方法的风轮转速预测误差均显著低于对比方法。在风速误差达到 1 m/s 时,所提方法的 $\mu(r)$ 仅为 1.192 %。该结果表明,相较于对比方法,利用所提方法构建的机组高维全局线性动态模型能够更好地应用于工程实际。

最后,利用 NVIDIA RTX 4060Ti 显卡训练该网络的耗时约为 6.2 小时。由于所提网络仅需在风电机组动态特性发生较大变化时重新训练,而该变化通

常由机组老化引起,是以月为单位的缓慢过程,因此该训练耗时能够满足实际应用的需求。

3.4 风电机组高维全局线性动态模型在风电场 MPC 策略中的效果

在风电场 MPC 策略中,机组动态模型在的主要作用可归纳为:赋予这些策略对机组风轮转速的精细化控制和约束能力,从而提升机组动态性能。

因此,通过以下方式评估所建风电机组高维全局线性动态模型在风电场

MPC策略中的有效性:

(1) 基于该模型构建了一种具有一般性的风电场MPC策略,如图5所示。作为一种MPC策略,该策略主要由三部分构成,即预测模型、代价函数以及约束条件。其中,预测模型为利用所提建模方法构建的风电机组高维全局线性动态模型,由式(18)所示,而代价函数和约束条件则根据具体控制目标在第4.2.1和4.2.2节中设计给出。在该策略下,风电场MPC控制器通过协同控制风电场内各个机组的有功功率输出与桨距角,在令风电场总有功功率输出跟踪有功功率参考值的同时,对各个机组的

转速开展精细化控制与约束。

(2) 分别量化分析该策略对机组转速的精细化控制和约束能力,从而评估所提机组高维全局线性动态模型在各类风电场MPC策略中的有效性。

至于(1)中有功率参考值的来源,其在不同控制场景下有所不同。由于本文的研究重点并不涉及具体的风电场控制策略,因此采用下式生成有功功率参考值:

$$P_{WF}^{ref} = \alpha P_{WF}^{avai} \quad (19)$$

式中: P_{WF}^{ref} 和 P_{WF}^{avai} 分别为风电场有功功率参考值和可捕获的最大风功率; α 为功率比例系数。




图5 风电场MPC策略

Fig. 5 MPC scheme for wind farm

为体现风电机组高维全局线性动态模型在建立风电场MPC策略方面的优势,本文还利用机组局部线性动态模型构建了上述MPC策略。下文将基于全局线性动态模型的策略简称为GLM-MPC策略,而将基于局部线性动态模型的策略简称为LLM-MPC策略。

利用SimWindFarm工具箱搭建了如图5所示的被控风电场。该风电场内包含9台NREL 5 MW风电机组,即

WT₁~WT₉。其中相邻两台风电机组的纵向间隔为600 m,横向间隔为400 m。随后,根据该机组空间分布,再次利用SimWindFarm工具箱为该风电场生成含湍流和机组尾流特征的风场。该风场中各机组的有效风速如图6所示。

基于上述设置,本文选取 $P_{WF}^{ref} < P_{WF}^{avai}$ 和 $P_{WF}^{ref} > P_{WF}^{avai}$ 这两个典型控制场景,分别验证GLM-MPC和LLM-MPC策略的风轮转速精细化控制能力和精细化约束

能力。




图6 风电机组的有效风速

Fig. 6 Effective wind speed of each wind turbine

4.2.1 控制场景1: $P_{WF}^{\text{ref}} < P_{WF}^{\text{avai}}$

该控制场景常见于风电场的有功功率控制, 以及电力系统高频事件时风电场的频率支撑控制。其特点在于, 充裕的风功率使机组的风轮转速具有较高的灵活性。因此, 通过将 α 设置为 0.7, 建立该场景, 来验证各策略对风轮转速的精细化控制能力。

首先, 将 GLM-MPC 和 LLM-MPC 策略的控制目标设置为: 在保证风电场有功输出等于其参考值的同时, 令各机组的风轮转速跟踪给定的转速参考曲线。该目标对应的代价函数和约束条件如下:

$$\min_{P_{c,k+h-1|k}^{\text{ref}}, \beta_{k+h-1|k}^{\text{ref}}} J = \sum_{h=1}^H \sum_{i=1}^{N_{WT}} (\omega_{r,k+h|k}^i - \omega_{r,k+h|k}^{\text{ref},i})^2 \quad (20a)$$

$$\sum_{i=1}^{N_{WT}} P_{c,k+h-1|k}^{\text{ref},i} = P_{WF,k+h-1|k}^{\text{ref}}, \quad h = 1, 2, \dots, H \quad (20b)$$

$$P_{c,\min} \leq P_{c,k+h-1|k}^{\text{ref},i} \leq P_{c,\max}, \quad i = 1, 2, \dots, N_{WT}, \quad h = 1, 2, \dots, H \quad (20c)$$

$$\beta_{\min} \leq \beta_{k+h|k}^i \leq \beta_{\max}, \quad i = 1, 2, \dots, N_{WT}, \quad h = 1, 2, \dots, H \quad (20d)$$

式中: 下标 $k+h|k$ 表示基于第 k 时刻可

获取的信息对第 $k+h$ 时刻变量的预测值; ω_r^{ref} 为机组风轮转速参考值; $P_{c,\min}$ 和 $P_{c,\max}$ 分别为机组有功功率输出的最小值和最大值; $\beta_{\min}$ 和 $\beta_{\max}$ 分别为机组桨距角的最小值和最大值; H 为 MPC 控制器的预测和控制时域; N_{WT} 为风电机组数量。

随后, 通过各机组对转速参考曲线的跟踪精度, 评价各策略的风轮转速精细化控制能力。本文引入以下平均绝对误差 (mean absolute error, MAE), 来量化该跟踪精度:

$$E_{1,i} = \frac{1}{N_T} \sum_{j=1}^{N_T} |\omega_{r,j}^i - \omega_{r,j}^{\text{ref},i}| \quad (21)$$

式中: $E_{1,i}$ 为控制场景 1 中, 第 i 台机组的实际转速与其转速参考值间的 MAE; N_T 为离散采样点的数量; ω_r^{ref} 为机组转速参考值。

图 7 和图 8 分别展示了两策略下各个机组的 $E_{1,i}$, 以及机组 WT₁、WT₄ 和 WT₇ 的风轮转速曲线。从图 7 可以看出, 相较于 LLM-MPC 策略, 在 GLM-MPC 策略下, 各个机组的 $E_{1,i}$ 均明显更

小。同时根据图8, 在GLM-MPC策略下, 机组WT₁、WT₄和WT₇的风轮转速曲线明显更加贴合参考曲线。上述结果

表明, GLM-MPC策略相较于LLM-MPC策略具有更加先进的机组风轮转速精细化控制能力。




图7 各个风电机组的转速跟踪误差

Fig. 7 Rotor speed tracking error of each wind turbine




图8 控制场景1下WT₁、WT₄和WT₇的风轮转速曲线

Fig. 8 Rotor speed curves of WT₁, WT₄, and WT₇ in control scenario 1

4.2.2 控制场景2: $P_{WF}^{ref} > P_{WF}^{avai}$

该场景常见于电力系统发生低频事件时, 对常态运行于最大功率点跟踪模式下的风电场, 所开展的电力系统频率支撑控制。其特点在于, 匮乏的风功率使风电机组不得不释放转子动能, 来实现风电场对有功功率参考值的跟踪。此时, 若不对风轮转速加以约束, 极易导致其向下越限。因此, 通过将 α 设置为1.2, 建立该场景, 验证各策略对机组风轮转速的精细化约束能力。

首先, 将GLM-MPC和LLM-MPC策略的控制目标设置为: 在尽可能确保

风电场总有功输出跟踪有功功率参考值的同时, 约束风轮转速, 避免其向下越限。该目标对应的代价函数和约束条件如下:

$$\min_{P_{c,k+h-1|k}^{ref}, P_{k+h-1|k}^{ref}} J = \sum_{h=1}^H (\zeta_{k+h-1|k})^2 \quad (22a)$$

$$\sum_{i=1}^{N_{WT}} P_{c,k+h-1|k}^{ref,i} + \zeta_{k+h-1|k} = P_{WF,k+h-1|k}^{ref} \quad (22b)$$

$$h = 1, 2, \dots, H$$

$$\omega_{r,min} \leq \omega_{r,k+h|k}^i, \quad h = 1, 2, \dots, H, \quad (22c)$$

$$i = 1, 2, \dots, N_{WT}$$

$$P_{c,min} \leq P_{c,k+h-1|k}^{ref,i} \leq P_{c,max}, \quad (22d)$$

$$i = 1, 2, \dots, N_{WT}, \quad h = 1, 2, \dots, H$$

$$\beta_{\min} \leq \beta_{k+h/k}^i \leq \beta_{\max},$$

$$i = 1, 2, \dots, N_{\text{WT}}, h = 1, 2, \dots, H \quad (22\text{e})$$

式中, $\omega_{r,\min}$ 为机组转速下限; ζ 为风电场有功功率输出的松弛变量。在机组的转子动能不足以支撑风电场继续准确跟踪有功功率参考值时, 该变量发挥作用, 对约束(22b)进行松弛, 以确保控制策略有解。同时, 通过将该松弛变量添加至代价函数(22a), 来降低控制指令对约束(22b)的违反程度, 使风电场尽可能跟踪有功功率参考值。

随后, 通过以下平均绝对误差量, 量化各控制策略下, 机组风轮转速的超限程度, 从而评价各策略对机组风轮转速的精细化约束能力:

$$E_{2,i} = \frac{1}{N_c} \sum_{j=1}^{N_i} \left| \min(0, \omega_{r,j}^i - \omega_{r,\min}) \right| \quad (23)$$

式中: $E_{2,i}$ 为场景2下, 第 i 台机组的转速跨越转速下限后, 与转速下限间的 MAE; $\omega_{r,\min}$ 为机组转速下限; N_c 为满足机组转速低于转速下限这一条件的离散采样点数量。




图9 各个风电机组的转速超限程度

Fig. 9 Rotor speed exceedance of each wind turbine

图9和图10分别展示了两控制策略下各机组的 $E_{2,i}$, 以及机组 WT₂、WT₅ 和 WT₈ 的风轮转速曲线。图9中的结果表明, 相较于 LLM-MPC 策略, 在 GLM-MPC 策略下, 各机组的转速超限程度均明显降低。同时, 根据图10, 在 LLM-MPC 策略下, 机组的转速直接跨越了转速下限; 而在 GLM-MPC 策略下, 风轮转速在下跌至转速下限后, 稳定维持在了该下限附近。上述结果表明, 相较于 LLM-MPC 策略, GLM-MPC 策略具有更加先进的风轮转速精细化约束能力。

综合4.2.1和4.2.2节中的验证结果

可知, 相较于 LLM-MPC 策略, GLM-MPC 策略在风轮转速精细化控制和精细化约束方面, 均存在明显优势。该优势可具体归因于 GLM-MPC 中所采用的风电机组高维全局线性动态模型。相较于 LLM-MPC 策略中仅在特定工作点附近准确的局部线性模型, 该模型能够在多变的风速和机组运行工况下保持准确, 从而能够更好地支撑 GLM-MPC 策略的控制决策。

同时, 在利用 Intel i5-10400F 处理器求解控制策略时, 在控制场景1下, GLM-MPC 和 LLM-MPC 策略的平均求解时间分别为 0.0278 s 和 0.0235 s; 在

控制场景2下,分别为0.0065 s和0.0051 s。该结果表明,所建模型的高维特性并不会显著增加MPC策略的在

线求解时间,从而保障了其在模型预测控制中的实用性。




图10 控制场景2下WT₂、WT₅和WT₈的风轮转速曲线

Fig. 10 Rotor speed curves of WT₂, WT₅, and WT₈ in control scenario 2

4 结论与展望

本文在Koopman算子理论的基础上,利用深度学习技术,提出了一种风电机组全局线性建模方法。该方法能够以数据驱动的方式,建立风电机组的高维全局线性动态模型。算例分析结果表明,与现有方法相比,所提方法在建模精度和建模泛化性方面均具有显著优势。同时,相较于风电机组的局部线性动态模型,利用所提高维全局线性动态模型构建的风电场MPC策略能够实现更加精确的机组转速控制与约束。

此外,所提方法仍具有一定的局限性。首先,作为一种基于深度学习的方法,所提方法的建模精度无法在理论层面以解析的形式进行量化;其次,所提方法构建的机组模型仅能对风轮转速和桨距角这两个基础状态的动态进行描述,使其无法应用于某些特殊风电场MPC策略,例如机组载荷抑制策略。

在未来,拟针对上述问题开展进一步研究。

参考文献

- [1] 李特,王荣喜,高建民.风电机组数据采集与监控系统异常数据识别方法[J].西安交通大学学报,2024,58(03):106-116.
LI T, Wang R, Gao J. A method for abnormal data recognition of wind turbine supervisory control and data acquisition systems [J]. Journal of Xi'an Jiaotong University, 2024, 58(03): 106-116.
- [2] 鲁宗相,李佳明,乔颖,等.新能源场站快速频率支撑能力评估研究现状与技术展望[J].电力系统自动化,2024,48(10):1-19.
LU Z, LI J, QIAO Y, et al. Research status and technology prospects of fast frequency support capability assessment for renewable energy stations [J]. Automation of Electric Power systems, 2024, 48(10): 1-19.
- [3] 叶林,路朋,赵永宁,等.含风电电力系统有功功率模型预测控制方法综述[J].中国电机工程学报,2021,41(18): 6181-6198.

- YE Lin, LU Peng, ZHAO Yongning, et al. Review of model predictive control for power system with large-scale wind power grid-connected[J]. *Proceedings of the CSEE*, 2021, 41(18): 6181-6198.
- [4] KOU P, LIANG D, YU L, et al. Nonlinear model predictive control of wind farm for system frequency support[J]. *IEEE Transactions on Power Systems*, 2019, 34(5): 3547-3561.
- [5] ARAGHI A R, RIAHY G H, CARLSON O, et al. Enhancing the net energy of wind turbine using wind prediction and economic NMPC with high-accuracy nonlinear WT models[J]. *Renewable Energy*, 2020, 151: 750-763.
- [6] Soleymani M, Bigdeli N, Rahmani M. Real-time time-varying economic nonlinear model predictive control for wind turbines[J]. *International Journal of Electrical Power & Energy Systems*, 2024, 159: 110019.
- [7] Yao Q, Zhang Y, Sun S, et al. Optimization of energy efficiency for offshore wind farms via wake modeling-free NMPC[J]. *Ocean Engineering*, 2024, 305: 117923.
- [8] LUNA J, FALKENBERG O, GROS S, et al. Wind turbine fatigue reduction based on economic-tracking NMPC with direct ANN fatigue estimation[J]. *Renewable Energy*, 2020, 147: 1632-1641.
- [9] YAO Q, MA B, ZHAO T, et al. Optimized active power dispatching of wind farms considering data-driven fatigue load suppression[J]. *IEEE Transactions on Sustainable Energy*, 2022, 14(1): 371-380.
- [10] ZHAO H, WU Q, WANG J, et al. Combined active and reactive power control of wind farms based on model predictive control[J]. *IEEE Transactions on Energy Conversion*, 2017, 32(3): 1177-1187.
- [11] HUANG S, WU Q, BAO W, et al. Hierarchical optimal control for synthetic inertial response of wind farm based on alternating direction method of multipliers[J]. *IEEE Transactions on Sustainable Energy*, 2020, 12(1): 25-35.
- [12] Cirio D, Conte F, Gabriele B, et al. Fast frequency regulation from a wind farm-BESS unit by model predictive control: Method and hardware-in-the-loop validation[J]. *IEEE Transactions on Sustainable Energy*, 2023, 14(4): 2049-2061.
- [13] WANG H, YANG Z, CHEN Z, et al. Multiple adaptive model predictive controllers for frequency regulation in wind farms[J]. *IEEE Transactions on Energy Conversion*, 2022, 38(1): 15-26.
- [14] Ebadollahi S, Saki S. Wind turbine torque oscillation reduction using soft switching multiple model predictive control based on the gap metric and Kalman filter estimator[J]. *IEEE Transactions on Industrial Electronics*, 2017, 65(5): 3890-3898.
- [15] KOOPMAN B O. Hamiltonian systems and transformation in Hilbert space[J]. *Proceedings of the National Academy of Sciences*, 1931, 17(5): 315-318.
- [16] GUO Z, WU W. Data-driven model predictive control method for wind farms to provide frequency support[J]. *IEEE Transactions on Energy Conversion*, 2021, 37(2): 1304-1313.
- [17] HUANG Z, WU W, GUO Z. Data-driven stochastic model predictive control for regulating wind farm power generation with controlled battery storage[J]. *IET Renewable Power Generation*, 2023, 17(14): 1-10.

- 3568-3581.
- [18] 孙正龙,李浩博,刘铖,等.含虚拟惯量的双馈风电机组扭振阻尼特性分析与抑制方法研究[J].电网技术,2021,45(12):4671-4683.
- SUN Zhenglong, LI Haobo, LIU Cheng, et al. Torsional oscillation damping characteristics and suppression methods of doubly-fed in-duction generator with virtual inertia[J]. Power System Technology, 2021, 45(12): 4671-4683.
- [19] 奥博宇,陈磊,闵勇,等.提升变桨减载风电机组调频性能的模糊前馈控制[J/OL].中国电机工程学报,1-16[20250512].<http://kns.cnki.net/kcms/detail/11.2107.tm.20250122.1723.002.html>.
- AO B, CHEN L, MIN Y, et al. Fuzzy feed-forward control to improve frequency regulation performance of deloaded wind turbine generator with pitch angle reserve [J]. Proceedings of the CSEE, 1-16 [20250512]. <http://kns.cnki.net/kcms/detail/11.2107.tm.20250122.1723.002.html>.
- [20] KORDA M, MEZIĆ I. Linear predictors for nonlinear dynamical systems: Koopman operator meets model predictive control[J]. Automatica, 2018, 93: 149-160.
- [21] MAMAKOUKAS G, ABRAHAM I, MURPHEY T D. Learning stable models for prediction and control[J]. IEEE Transactions on Robotics, 2023, 39(3): 2255-2275.
- [22] KINGMA D P, BA J. Adam: a method for stochastic optimization[J/OL]. arxiv: 1412.6980, 2014.
- [23] GRUNNET J D, SOLTANI M, KNUDSEN T, et al. Aeolus toolbox for dynamics wind farm model, simulation and control[C]// The European Wind Energy Conference & Exhibition, April 20-23, 2010, Warszawa, Poland.
- [24] JONKMAN J, BUTTERFIELD S, MUSIAL W, et al. Definition of a 5-MW reference wind turbine for offshore system development[R]. Golden: National Renewable Energy Laboratory, 2009.
- [25] HUANG S, WU Q, GUO Y, et al. Bi-level decentralised active power control for large-scale wind farm cluster[J]. IET Renewable Power Generation, 2018, 12(13): 1486-1492.
- [26] 殷豪,曾云,孟安波,等.基于奇异谱分析-模糊信息粒化和极限学习机的风速多步区间预测[J].电网技术,2018,42(05):1467-1474.
- YIN Hao, ZENG Yun, MENG Anbo, et al. Wind speed multi-step interval prediction based on singular spectrum analysis-fuzzy information granulation and extreme learning machine[J]. Power System Technology, 2018, 42(05): 1467-1474.
- [27] 常雨芳,杨子潇,潘风,等.基于CEEMDAN-PE-WPD和多目标优化的超短期风电功率预测方法[J].电网技术,2023,47(12):5015-5026.
- CHANG Yufang, YANG Zixiao, PAN Feng, et al. Ultra-short-term wind power prediction based on CEEMDAN-PE-WPD and multi-objective optimization[J]. Power System Technology, 2023, 47(12): 5015-5026.