

基于物理信息的时间卷积神经网络风电功率预测

张维通, 闫正兵, 张正江, 黄世沛, 戴瑜兴

(温州大学 电气数字化设计技术国家地方联合工程研究中心, 浙江 温州 325035)

摘要: 由于风力的不确定性和随机性, 风电功率预测对电力系统的稳定运行至关重要; 为提高风电功率模型的预测精度; 对风力发电机的数学模型进行研究后, 将物理建模和数据驱动建模相结合, 提出一种基于物理信息的时间卷积神经网络模型用于风力发电机的功率预测; 采用将风力发电机的转子运动方程嵌入时间卷积神经网络的损失函数, 从而提高模型的预测能力, 泛化性和物理可解释性; 并在 Simulink 仿真软件中搭建风力发电机物理模型以获取实验数据样本, 经同工况实验和外推实验表明, 基于物理信息的时间卷积神经网络模型相较于原时间卷积神经网络模型的同工况实验均方根误差下降 50.8%, 外推实验的均方根误差下降 55.2%, 显著提高了风力功率预测的准确性。

关键词: 风力发电机; 功率预测; 物理信息; 时间卷积神经网络; 数据驱动建模

Temporal Convolutional Neural Network for Wind Power Prediction Based on Physical Information

ZHANG Weitong, YAN Zhengbing, ZHANG Zhengjiang, HUANG Shipai, DAI Yuxing

(National and Local Joint Engineering Research Center for Digital Electrical Design Technology,
Wenzhou University, Wenzhou 325035, China)

Abstract: Due to the uncertainty and randomness of wind power, it is very important to predict wind power in the stable operation of power system. To improve the prediction accuracy of wind power model; After studying the mathematical model of wind turbine, combining physical modeling and data-driven modeling, a temporal convolutional neural network model based on physical information is proposed to predict the power of wind turbine. The rotor motion equation of the wind turbine is embedded into the loss function of the temporal convolutional neural network, so as to improve the prediction ability, generalization and physical interpretability of the model. The physical model of the wind turbine is built in Simulink simulation software to obtain experimental data samples. Through experiments under the same working conditions and extrapolation experiments, the results show that compared with the original temporal convolutional neural network model, the temporal convolutional neural network model based on physical information reduces the root mean square error by 50.8%, and the root mean square error of the extrapolation experiment is reduced by 55.2%, significantly improving the accuracy of wind power prediction.

Keywords: wind turbine; power prediction; physical information; temporal convolutional neural network; data-driven modeling

0 引言

随着“双碳”战略目标的实施与推进, 我国风电开发建设规模进一步扩大并建设以新能源为主的新型电力系统^[1]。风力发电虽然能够提供清洁能源, 但风力发电受环境因素影响较大, 具有间歇性和波动性, 这给电网的运行和控制带来挑战^[2-3]。因此对风力发电功率的精准预测对电网稳定运行至关重要。

目前风力功率的预测方法主要可分为物理建模方法和

数据驱动方法两类^[4]。物理建模方法通常是指基于物理原理和气象学模型的预测方法。例如, 文献 [5] 提出使用气象研究与预报模型和风力发电厂参数化建模方法对海上风电场进行风力发电预测模拟^[5]; 文献 [6] 提出一种基于对数值天气预报特征间联合效应的复合协方差函数高斯过程预测模型用于风电功率的高精度预测^[6]; 文献 [7] 提出了一种前后风轮干涉条件下的双风轮风电机组气动 MIMO 系统全工况分段仿射自回归 (PWARX) 建模方案^[7]。文献

收稿日期: 2024-04-24; 修回日期: 2024-06-05。

基金项目: 温州市科研项目 (ZF2022003); 工业控制技术国家重点实验室开放课题 (ICT2022B65); 温州市高水平创新团队项目 (温委人 (2020)3 号); 电气数字化设计技术国家地方联合工程。

作者简介: 张维通 (2000-), 男, 硕士。

通讯作者: 闫正兵 (1983-), 男, 副教授。

张正江 (1982-), 男, 教授。

戴瑜兴 (1956-), 男, 国家二级教授。

引用格式: 张维通, 闫正兵, 张正江, 等. 基于物理信息的时间卷积神经网络风电功率预测[J]. 计算机测量与控制, 2024, 32(11): 101-108, 117.

[8] 将虚拟同步控制技术应用用于风力涡轮机, 搭建了双馈风力发电机的阻抗模型, 并在 MATLAB/Simulink 中进行了时域仿真验证了其建模模型的准确性^[8]。文献 [9] 以小型垂直轴风力机系统为例, 结合气象风场数据, 验证了计算流体力学 (CFD) 仿真预测风力发电的准确性^[9]。

数据驱动方法主要通过历史数据来拟合输入与输出之间的映射关系。近年来随着深度学习和大数据的快速发展, 数据驱动方法也广泛应用于风力功率预测。例如, 文献 [10] 提出了一种基于 EMD-CCTransformer 的风力发电预测方法, 使用 EMD 算法对风力序列进行分解, 引入了卷积注意力机制来替代点积注意力机制形成了 CCTransformer 模型^[10]; 文献 [11] 提出了一种基于贝叶斯框架的双向门控逻辑单元 (BiGRU) 方法, 将编码器-解码器 (ED) 架构与 BiGRU 时间序列建模和特征-时间注意力 (FT-Attention) 相结合, 以提高风电功率预测的准确性^[11]; 文献 [12] 考虑了多风电场之间的关联性, 将自然语言处理 (NLP) 领域的 Transformer 网络应用于多风电场的短期功率预测^[12]; 文献 [13] 提出基于时间卷积神经网络的风电功率预测, 通过采用扩张因果卷积和残差连接来解决深度卷积模型在序列预测中的长期依赖问题和性能衰减问题^[13]; 文献 [14] 提出一种基于时间卷积神经网络和窗口概率稀疏 Transformer 的结合模型用于风力功率预测^[14], 通过引入窗口概率稀疏多头注意力机制, 将较为重要的短期特征纳入注意力机制提高了模型的预测能力。文献 [15] 提出了一种连续条件随机场模型, 结合双向长短期记忆神经网络 (Bi-LSTM) 和高斯核函数 (GKs), 该模型综合考虑了数值天气预报 (NWP) 与风电功率的相关性以及风电功率的时间自相关性, 提高了模型的预测精度^[15]。文献 [16] 则是提出了一种基于流形学习的双层共享权重长短期记忆网络预测模型, 考虑了气象环境因素、风力发电机参数和历史风电功率的影响, 利用流形学习方法对高维数据集进行降维, 构建了双层共享权重长短期记忆网络预测模型以提高预测精度^[16]。文献 [17] 则是改进 KNN (K-Nearest Neighbor)

算法并结合 K-means 算法进行风电功率的短期预测^[17]。

然而上述两种方法都有其缺陷。首先物理模型需要大量的前置假设^[1]; 并且由于物理模型的许多参数无法直接测量, 所以其准确度依赖模型参数辨识的准确度, 目前也有许多学者进行风电模型的参数辨识研究^[18-20]; 为了尽可能详细地描述风力发电机的发电过程, 所建立的模型可能比较复杂, 包含许多微分方程和其他数学表达式, 所以其运行计算时间通常较长。对于数据驱动模型来说, 其需要海量数据来进行模型的拟合; 并且数据驱动模型大多都是黑盒模型缺乏物理可解释性, 在某些情况下可能会给出违反物理规律的结果; 而且数据驱动模型的泛化性较差也就是对于未知工况下的预测能力较差。

针对以上问题, 本文提出了基于物理信息的时间卷积神经网络模型进行风力发电机功率预测。该模型通过嵌入风力发电机的转子运动方程, 使得模型在训练中不仅能够

学习到数据本身的特征还能够学习到物理规律中包含的物理信息。通过融合物理信息让本文提出模型具有明确的物理意义, 不再是一个完全的黑盒模型。从而提高了模型的预测精度, 物理可解释性和泛化性。

在第一章中本文将介绍风力发电机的数学模型并在 Simulink 中搭建风力发电机的仿真模型, 通过仿真模型获取数据样本; 在第二章中则是介绍了本文提出的基于物理信息的时间卷积神经网络模型的结构和原理; 在第三章中通过算例分析进行了同扰动风情况下的功率预测实验和不同扰动风情况之间的外推预测实验, 通过实验得出在同扰动风情况下本文物理信息的时间卷积神经网络模型相较于原时间卷积神经网络模型的均方根误差下降了 50.8%, 在外推实验中下降了 55.2%。通过以上实验验证了本文提出方法能够提高同扰动风及不同扰动风情况下的预测精度。

1 风电机组的数学模型与搭建

1.1 风力机模型

通过空气动力学特性分析, 在忽略外界阻尼等影响情况下, 可得到风力机的数学模型表达式如下:

$$P_m = \frac{1}{2} \rho \pi R^2 v^3 C_p(\lambda, \beta) \quad (1)$$

$$T_m = \frac{P_m}{\omega_m} \quad (2)$$

式中, P_m 表示风力机输出的机械功率, T_m 表示输出的机械转矩, ρ 表示空气密度, R 表示风机的叶片半径, v 表示风速, ω_m 为风力机转速。 $C_p(\lambda, \beta)$ 表示风能利用系数, 其用于评估风电机组能量转换效率, 一般通过经验拟合方式得到其曲线关系^[21], 如式 (3) ~ (4):

$$C_p(\lambda, \beta) = C_1 \left(\frac{C_2}{\lambda_i} - C_3 \beta - C_4 \right) e^{-C_5/\lambda_i} + C_6 \lambda \quad (3)$$

$$\frac{1}{\lambda_i} = \frac{1}{\lambda + 0.08\beta} - \frac{0.035}{\beta^3 + 1} \quad (4)$$

式中, $C_1 \sim C_6$ 为系数, β 为桨距角, λ 为叶尖速比, 其中叶尖速比表达式如式 (5) 所示:

$$\lambda = \frac{R\omega_m}{v} \quad (5)$$

1.2 风速模型

外界风速直接决定了机组的输出与工作状态, 本文将采集不同组合风速模型下的数据作为样本。

1) 基本风:

基本风为一段时间内的平均风速, 其决定了风电机组的额定功率, 建模时视为常数。如式 (6):

$$v = c \quad (6)$$

2) 阵风:

阵风模拟风速突然增加并持续一段时间的特征, 建模时通常使用余弦函数进行表达如式 (7) 所示:

$$v(t) = \begin{cases} 0 & t < t_s \\ \frac{V_{\max}}{2} \left[1 - \cos 2\pi \left(\frac{t-t_s}{T} \right) \right] & t_s \leq t \leq t_s + T \\ 0 & t > t_s + T \end{cases} \quad (7)$$

15 s, 仿真单次需要 162.18 s。

表 2 风速类型及风速

风速类型	风速(每类)/(m/s)
阵风	3~8
渐变风	3~8
噪声风	3~8
阵风—渐变风	2~6
阵风—噪声风	2~6
渐变风—噪声风	2~6
阵风—渐变风—噪声风	1~4

2 基于物理信息的时间卷积神经网络

针对物理模型运算时间长, 需要参数辨识; 传统深度学习模型缺乏物理可解释性, 预测精度低, 外推效果差等问题。本文提出基于物理信息的时间卷积神经网络模型, 将其将风力发电机中的转子运动方程嵌入时间卷积神经网络中, 使得网络的预测符合物理规律从而提高预测精度和外推能力。

物理信息神经网络的概念最早是 Owhadi 于 2015 年所提出的物理知识学习机的想法, 其揭示了利用先验知识技术的可行性^[22]。Raissi 等人在 2017 年进一步介绍了物理信息网络并在 2019 年正式发布了物理信息网络 (Physical Information Neural Network)^[23-24]。物理信息神经网络的特点是利用科学知识或物理定律来指导神经网络的优化, 设计和实现^[25]。这使得物理信息神经网络不仅可以学习数据的固有特征还可以学习其潜在的物理定理使网络更具有可解释性和适用性。

而时间卷积神经网络是一种是用于序列数据建模的深度学习模型, 它采用了卷积神经网络 (CNN) 的结构来捕捉序列数据中的局部模式和长期依赖关系^[26]。时间卷积神经网络是基于一系列扩展的一维卷积时间块。每个时间模块都有相同的基本结构, 其模块结构如图 2 所示。

它有 2 个卷积层, 其中穿插着权值归一化、dropout 和非线性层。其中扩张卷积 (Dilated Convolution) 是其显著特征, 扩张卷积可以在卷积时进行间隔采样, 感受野的大小则会根据层数的增加而指数增长, 从而使得网络可以在较少层数下具有较大的感受野以获取更多信息^[14]。权值归一化层 (Weight Norm) 重新参数化网络权值有利于提高网络的收敛性^[27]。Dropout 层可以防止过拟合。并且使用了残差连接, 这可以很好地避免梯度消失和梯度爆炸的问题。

目前已有一些将时间卷积神经网络应用于风力发电机功率预测^[28-29]并取得一些成果。本文将风力发电机中的转子运动方程嵌入时间卷积网络搭建基于物理信息的时间卷积神经网络模型用于风力发电机的功率预测。嵌入的风力发电机转子运动方程如式 (11) ~ (13) 表示:

$$T_j \frac{d\omega}{dt} = T_m - T_e \quad (11)$$

$$T_m = \frac{P_m}{\omega} \quad (12)$$

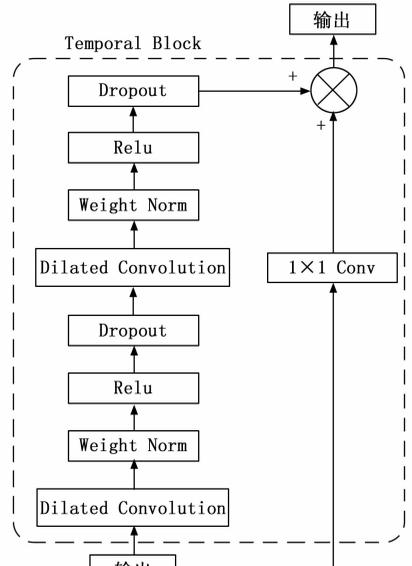


图 2 时间卷积模块结构

$$T_e = \frac{P_e}{\omega} \quad (13)$$

其中: T_j 为风力发电机的转动惯量, ω 为角速度, P_m 为机械功率, P_e 为电磁功率, T_m 为机械转矩, T_e 是电磁转矩。

本文提出的网络结构如图 3 所示。由上侧的时间卷积神经网络和下侧的损失计算组成。时间卷积神经网络的结构由通道数分别为 [8, 16, 16, 32, 32, 32] 的时间卷积模块组成。最后通过全连接层进行模型输出。模型的输入为时间, 桨距角, 风速和机械功率; 输出为角速度和功率。损失函数由物理损失 $loss_f$ 和预测损失 $loss_p$ 组成如式 (14)。

其中物理损失如式 (15) 所示, 通过神经网络的自动微分计算出角速度 ω 对时间 t 的微分再带入上式 (11) ~ (13) 中并通过均方根误差 (RMSE) 计算其与 0 的误差。均方根误差计算公式如式 (16) 所示, 其中 \hat{x} 为真实值, x 为预测值, N 为数据点总数。当输入和输出之间的关系不满足上述的转子运动方程时, 物理损失将会增大从而增大总误差进而调整神经网络参数, 使模型的输出更符合物理规律。预测损失如式 (17) 所示 ($\hat{\omega}, \hat{p}$) 为真实值, (ω, p) 为预测值, 同样通过均方根误差计算二者的损失作为预测损失。

$$loss = loss_p + \frac{loss_f}{q} \quad (14)$$

$$loss_f = RMSE(T_j \frac{d\omega}{dt} - \frac{P_m - P}{\omega}, 0) \quad (15)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (\hat{x} - x)^2}{N}} \quad (16)$$

$$loss_p = RMSE[(\hat{\omega}, \hat{p}), (\omega, p)] \quad (17)$$

由于物理损失需要将输出逆归一化后进行计算, 所以物理损失的数量级远远大于预测损失。为了避免因物理损失和预测损失的数量级相差过大从而导致预测损失失效的情况, 将物理损失函数除物理损失和预测损失数量级之差 q

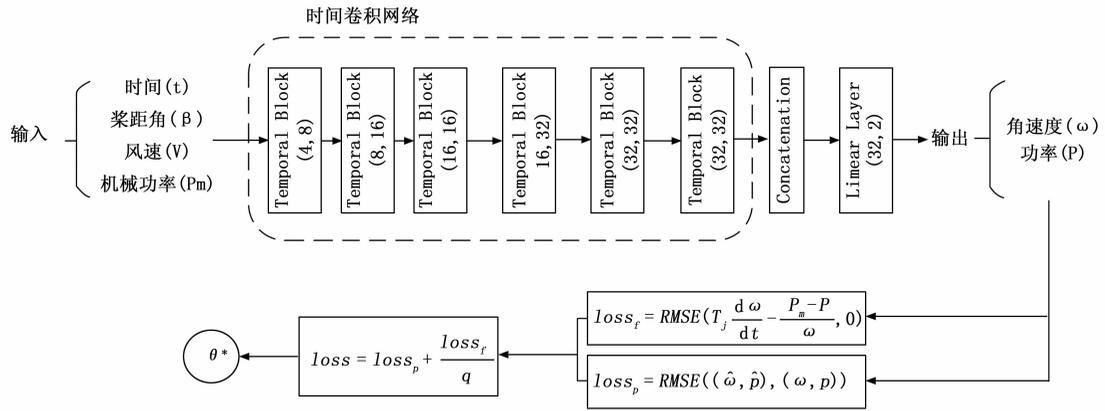


图 3 基于物理信息的时间卷积神经网络结构

以平衡二者的数量级。将二者按权重相加后得到最终的误差，根据误差来调整神经网络参数 θ^* 。模型具体的训练过程如下算法 1 中的伪代码所示。

算法 1: PITCN 网络训练伪代码

输入: 训练集 $D = \{x^n = t, \beta, V, P_m, y^n = \omega, P\}$,

验证集 V , 学习率, Drop 率, 迭代次数, 网络层数

1) 初始化网络参数 $\theta^* = \{\omega, b\}$

2) for $i = 1 \dots N$ do

3) 从训练集 D 中随机抽取样本 $[x^{(n)}, y^{(n)}]$

4) 前馈计算出模型的输出 (ω, P)

// 计算角速度关于时间的微分

5) $\frac{d\omega}{dt} = \text{AutoDiff}(\hat{\omega}, t)$

// 计算物理损失

6) $loss_f = \text{RMSE}(T_j \frac{d\omega}{dt} - \frac{P_m - P}{\omega}, 0)$ // 公式(15)

// 计算预测损失

7) $loss_p = \text{RMSE}[(\hat{\omega}, \hat{p}), (\omega, p)]$ // 公式(17)

// 计算总损失

8) $loss = loss_p + \frac{loss_f}{q}$ // 公式(14)

9) 根据损失更新网络参数 $\theta^* = \{\omega, b\}$

10) end

11) 输出: PITCN 网络模型

在数据驱动的方法中，大量数据被用来拟合输入和输出之间的非线性关系。而基于物理信息的时间卷积网络将物理信息和时间卷积网络结合起来在数据驱动的基础上还能学习到物理规律，从而使得时间卷积神经网络的输出更符合物理关系。因此与数据驱动的方法相比，基于物理信息的时间卷积神经网络具有更清晰的物理意义可解释性。

3 实验结果与分析

3.1 数据集及仿真设置

本文数据集由第 1 章中搭建的 Simulink 风力发电机物理模型采集。采集表 2 中不同风速情况下的数据样本作为本文数据集。仿真时间为 15 s，扰动风影响时间为 1~15 s，采样时间为 0.01 s。输入特征为时间，桨距角，风速，机械功率；输出特征为角速度，功率。为提高模型训练的稳

定性本文对数据集进行归一化，归一化公式如式 (18)：

y 是原始数据， y_{\min}, y_{\max} 分别为原始数据最小值和最大值。

$$y_i = \frac{y - y_{\min}}{y_{\max} - y_{\min}} \quad (18)$$

式中， y_i 为处理后数据。

本文使用的仿真环境为：Windows10 操作系统，16 GB RAM，CPU 为 Intel Core i7-12700，GPU 为 NVIDIA GeForce GTX 1660 Ti，采用 Python3.8 语言，Pytorch 框架搭建本文神经网络模型。在此仿真环境下本文提出模型仿真一次的时间为 1.78 s，远小于上述第 1 章中 Simulink 仿真的 162.18 s。这对于电力系统来说至关重要，因为电力系统对于灵敏性和速动性的要求较高，有利于工作人员快速发现功率的异常状态。并且仿真时间短有利于未来优化系统参数。

为验证本文提出物理信息时间卷积神经网络模型 (PITCN, physical information temporal convolutional neural network) 在同工况与不同工况情况下的优越性，将其与长短期记忆网络 (LSTM, long short-term memory) 模型和原始时间卷积神经网络 (TCN, temporal convolutional neural network) 进行对比。两种对比模型的通道数，层数，训练参数与本文提出模型一致。

3.2 同工况实验

同工况实验通过对比验证同一类扰动风速下的预测效果，其数据集分割情况如表 3 所示。将以每类扰动风速较小的两个风速数据作为训练集和验证集，其中 80% 作为训

表 3 同工况实验数据集分割

风速类型	训练集	验证集	测试集
阵风	(3,4) * 80%	(3,4) * 20%	5,6,7,8
渐变风	(3,4) * 80%	(3,4) * 20%	5,6,7,8
噪声风	(3,4) * 80%	(3,4) * 20%	5,6,7,8
阵风-渐变风	(2,3) * 80%	(2,3) * 20%	4,5,6
阵风-噪声风	(2,3) * 80%	(2,3) * 20%	4,5,6
渐变风-噪声风	(2,3) * 80%	(2,3) * 20%	4,5,6
阵风-渐变风-噪声风	(1,2) * 80%	(1,2) * 20%	3,4

表 4 单类风情况下预测均方根误差

风速/(m/s)	阵风			渐变风			噪声风		
	LSTM	TCN	PITCN	LSTM	TCN	PITCN	LSTM	TCN	PITCN
5	348.67	113.66	37.10	329.10	110.28	51.02	330.58	150.33	70.31
6	351.11	130.57	52.92	329.73	112.10	54.07	332.45	180.33	93.24
7	354.75	151.91	71.31	330.72	114.57	58.96	333.70	155.01	79.02
8	359.41	175.03	91.60	332.21	117.81	66.44	335.90	158.27	84.50

表 5 两类风叠加情况下预测均方根误差

风速/(m/s)	阵风—渐变风			阵风—噪声风			渐变风—噪声风		
	LSTM	TCN	PITCN	LSTM	TCN	PITCN	LSTM	TCN	PITCN
4	333.71	154.94	61.64	368.08	228.95	76.26	333.51	180.46	78.21
5	341.64	178.66	75.92	377.18	246.06	91.23	335.95	187.82	86.27
6	349.79	204.80	97.50	387.52	276.55	110.71	338.54	193.95	93.47

练集, 20%作为验证集。将剩余较大风速下的数据作为测试集进行效果验证。例如阵风情况下以 3 m/s, 4 m/s 扰动风下的数据作为训练集和验证集, 将 5~8 m/s 扰动风下的数据作为测试集。

为了评估模型测试结果, 选择均方根误差作为评价指标。其值越小表明模型预测效果越好。模型预测结果如表 4~6 分别为单类风, 两类叠加风和 3 类叠加风情况下的预测均方根误差, 为避免偶然性以下结果均为 5 次训练的均值。表中 LSTM 为长短期记忆网络, TCN 为时间卷积神经网络, PITCN 为本文提出的物理信息时间卷积神经网络。

由上表中结果可看出本文提出的物理信息时间卷积神经网络模型效果在各类情况下均好于 LSTM 模型与原时间卷积神经网络模型。其中单类风情况下本文提出模型较原时间卷积神经网络模型的均方误差下降了 51%, 在两类风叠加情况下均方误差下降了 57.8%, 3 类风情况下均方误差下降了 43.8%。为了更清晰地看出本文提出模型的训练稳定性和预测的优异性, 本文绘制出了模型的箱线图如下图所示。从以下图中可看出本文提出的 PITCN 模型的均方误差明显更小, 预测精度更好。并且由于物理信息的嵌入使得模型的训练更加稳定, 由图中可以明显看出原 TCN 模型训练不稳定, 均方误差分布更长。而本文提出模型在各类情况不仅预测效果更好并且模型训练稳定。

3.2 外推实验

由于现实中风速类型更加多样复杂, 所以模型的训练

表 8 两类风情况下外推预测均方根误差

风速/(m/s)	阵风—渐变风			阵风—噪声风			渐变风—噪声风		
	LSTM	TCN	PITCN	LSTM	TCN	PITCN	LSTM	TCN	PITCN
2	309.38	110.25	38.77	311.30	114.77	36.58	313.41	129.85	67.00
3	316.39	120.83	48.96	309.70	111.94	34.21	311.44	126.54	59.95
4	328.14	151.50	79.16	311.41	118.09	42.62	314.39	182.43	96.32
5	341.19	191.93	118.73	316.19	131.66	55.97	316.47	211.80	108.37
6	355.57	238.52	164.09	323.32	150.32	71.83	318.78	234.12	119.39

表 6 3 类风情况下预测均方根误差

风速/(m/s)	阵风—渐变风—噪声风		
	LSTM	TCN	PITCN
3	335.81	154.94	92.55
4	342.78	202.77	108.30

集中不可能包含所有的风速类型。那么在此情况下, 模型的泛化性也就是模型外推至不同扰动风类型下的预测能力就至关重要。本文将使用上述实验中的阵风训练模型对其他类型扰动风进行外推实验。与上述同工况实验相同将与 LSTM 模型和原始时间卷积神经网络模型进行对比, 对比指标同样为均方根误差。各模型的外推预测结果如表 7~9 分别为单类风, 两类叠加风和 3 类叠加风情况下的外推预测均方根误差, 为避免偶然性以下结果均为 5 次训练的均值。

表 7 单类风情况下外推预测均方根误差

风速/(m/s)	渐变风			噪声风		
	LSTM	TCN	PITCN	LSTM	TCN	PITCN
3	311.43	124.51	55.63	324.02	190.79	101.32
4	311.71	122.32	51.42	324.94	206.74	109.55
5	314.56	122.80	51.69	326.36	224.70	119.55
6	318.78	127.10	56.75	332.40	252.49	137.28
7	323.71	136.42	66.37	330.81	264.44	143.67
8	328.69	149.72	79.82	333.89	285.84	157.25

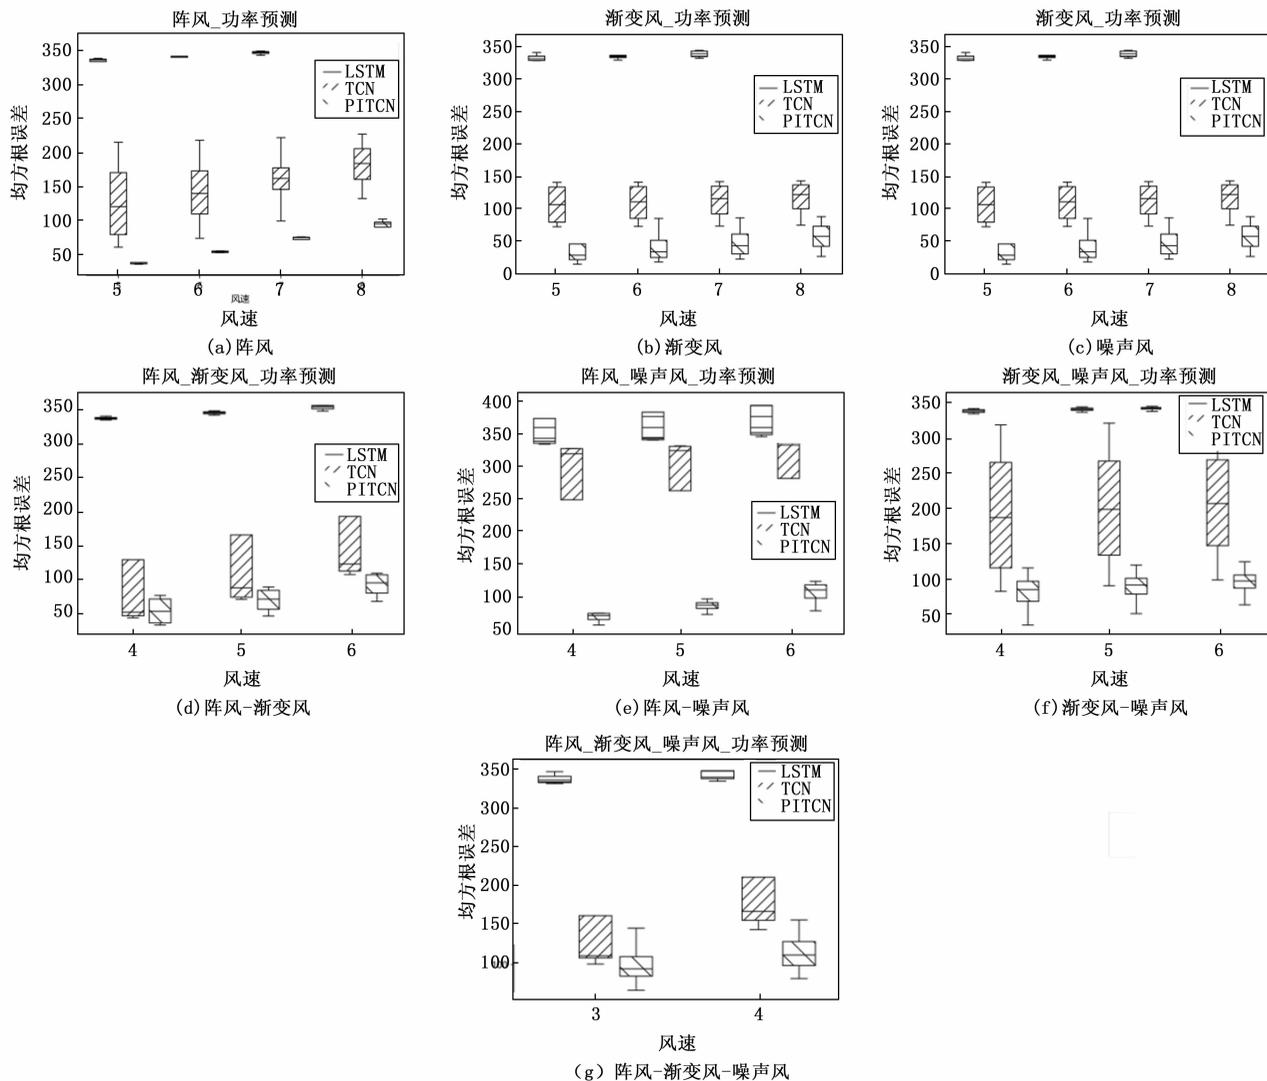


图 4 不同扰动风情况下的均方根误差箱线图

表 9 3 类风情况下外推预测均方根误差

阵风—渐变风—噪声风			
风速/(m/s)	LSTM	TCN	PITCN
1	311.99	120.02	53.06
2	309.38	111.70	40.55
3	316.82	125.55	53.31
4	329.65	157.99	83.65

由上表可看出本文提出的物理信息时间卷积网络模型在各类扰动风速情况下的外推预测效果均好于 LSTM 模型与原始时间卷积网络模型。具体来说在单类扰动风的情况下本文提出模型相比原时间卷积网络模型的外推预测均方根误差下降了 49.9%，在两类扰动风叠加情况下本文提出模型相比原时间卷积模型的外推预测均方根误差下降了 51.7%，在 3 类扰动风叠加情况下本文提出模型相比原时间卷积网络模型的外推预测均方根误差下降了 55.2%。上

述结果表明，在嵌入物理信息后的时间卷积网络模型在外推到其他扰动风情况下的预测能力大大提高。为了更清晰地看出本文提出模型的在外推情况下的优越性，本文绘制出了模型的外推箱线图如图 5 所示。由图中可看出相比于同工况的预测来说，外推情况下的原时间卷积网络模型表现更加不稳定，这是因为其未学习到数据中潜在的物理关系，预测出的结果是不符合物理规律的。而嵌入物理信息后的时间卷积网络模型在预测中较为稳定。这是因为嵌入物理信息后，模型能从中学习到相关的物理规律。从而使得模型的解是一个更加符合物理定律的可行解，使得模型更具有物理可解释性，具有更好的外推预测效果。

4 结束语

为提高各类情况下风电功率预测的准确度。本文提出基于物理信息的时间卷积神经网络模型用于风力发电机的功率预测。通过将风力发电机的转子运动方程嵌入时间卷积神经网络的损失函数，使网络能够学习到物理信息从而

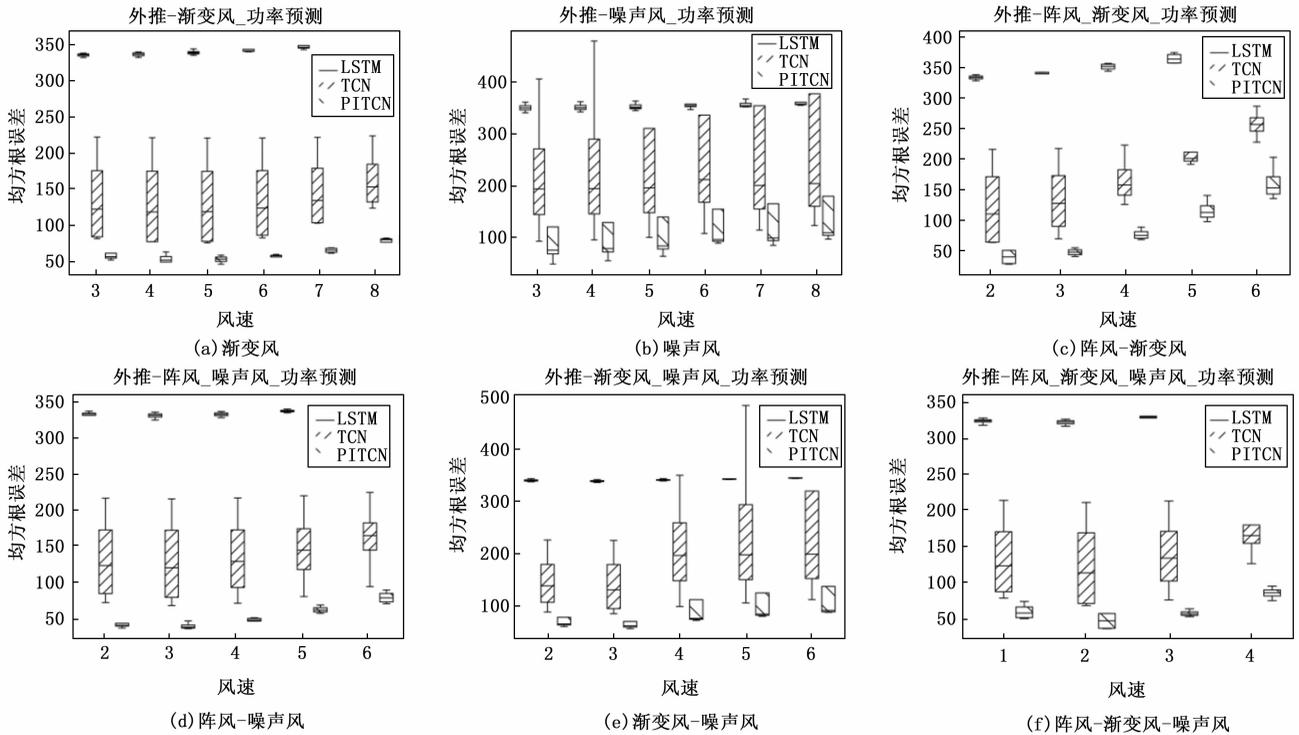


图 5 外推至不同扰动风情况下的均方根误差箱线图

提高模型的预测精度和外推预测能力，提高物理可解释性。本文通过 Simulink 来搭建风力发电机物理模型来获取数据样本并作为对比。通过同类扰动风实验和不同扰动风间外推实验验证本文提出基于物理信息的时间卷积神经网络模型的可行性和优越性。实验结论表明本文提出的基于物理信息的时间卷积神经网络模型相较于原时间卷积神经网络模型在同类风情况下的均方根误差下降了 50.8%，在不同扰动风间的外推实验中的均方根误差下降了 55.2%。以上结果说明本文提出模型在同类风情况和外推情况中均表现优异，提高了风电功率预测精度。

参考文献:

[1] 骆 钊, 吴论侯, 朱家祥, 等. 基于多尺度时间序列块自编码 Transformer 神经网络模型的风电超短期功率预测 [J]. 电网技术, 2023, 47 (9): 3527-37.

[2] 时志雄, 朱 峰, 刘 舒, 等. 基于 1DCNN-DACLSTM 模型的风电超短期功率预测方法 [J]. 电子器件, 2024, 47 (1): 194-200.

[3] 黄贤明, 郝雨辰, 霍雪松, 等. 基于时空混合注意力机制的超短时风电功率预测方法 [J]. 现代电力, 2024, 41: 1-9.

[4] 牛东晓, 纪会争. 风电功率物理预测模型引入误差量化分析方法 [J]. 电力系统自动化, 2020, 44 (8): 57-65.

[5] ZHAO Y N, XUE Y, GAO S H, et al. Computation and analysis of an offshore wind power forecast: towards a better assessment of offshore wind power plant aerodynamics [J]. Energies, 2022, 15 (12): 4223.

[6] FANG S C, CHIANG H D. A high-accuracy wind power forecasting model [J]. Ieee Transactions on Power Systems, 2017,

32 (2): 1589-1590.

[7] 胡 阳, 王浩楠, 房 方, 等. 串联式双风轮发电机组气动特性建模及仿真 [J]. 动力工程学报, 2023, 43 (10): 1308-1315.

[8] CHAI Z S, LI H, XIE X J, et al. Output impedance modeling and grid-connected stability study of virtual synchronous control-based doubly-fed induction generator wind turbines in weak grids [J]. International Journal of Electrical Power & Energy Systems, 2021, 126: 106601.

[9] TOMINAGA Y. CFD prediction for wind power generation by a small vertical axis wind turbine: a case study for a university campus [J]. Energies, 2023, 16 (13): 4912.

[10] LI N, DONG J, LIU L Y, et al. A novel EMD and causal convolutional network integrated with transformer for ultra short-term wind power forecasting [J]. International Journal of Electrical Power & Energy Systems, 2023, 154: 109470.

[11] LIU L, LIU J C, YE Y, et al. Ultra-short-term wind power forecasting based on deep bayesian model with uncertainty [J]. Renewable Energy, 2023, 205: 598-607.

[12] QU K, SI G Q, SHAN Z H, et al. Short-term forecasting for multiple wind farms based on transformer model [J]. Energy Reports, 2022, 8: 483-490.

[13] ZHU R J, LIAO W L, WANG Y S. Short-term prediction for wind power based on temporal convolutional network [J]. Energy Reports, 2020, 6: 424-429.

[14] 徐 钜, 谢开贵, 王 宇, 等. 基于 TCN-Wpsformer 混合模型的超短期风电功率预测 [J]. 电力自动化设备, 2024, 44 (8): 54-61.

(下转第 117 页)