

采用融合 MM5 模式的神经网络预测风电功率研究

曾昌学¹
ZENG Changxue

摘 要

短期风速精准预测是风电场总发电量预估的核心环节，但单一模型难以兼顾气象场推演与场站精细化修正的需求。针对该难题，文章提出一种融合第五代中尺度气象模型（MM5）与神经网络的混合短期风速预测方法。风机小时平均风速作为发电量计算的关键输入参数，该方法以全球数值天气预报数据为基础，将多高度层实测观测数据作为 MM5 模式的初始场与边界条件完成气象场模拟；再通过神经网络对 MM5 模式输出的粗分辨率气象结果进行误差订正与降尺度处理，得到风电场各点位精细化小时风速预报。以西班牙东南部实际风电场开展实例验证，实验结果表明，所提 MM5 神经网络混合框架可有效实现风电场点位短期风速高精度预测，具备良好的工程应用效果。

关键词

短期风速预测；全球预测模型；降尺度；神经网络

doi: 10.3969/j.issn.1672-9528.2026.07.018

0 引言

当前全球面临持续的能源危机，开发利用替代能源，已成为发达国家缓解高油价冲击的重要途径。风能是目前应用最广泛的替代能源之一，在欧洲的能源消费占比约为 10%，在德国、西班牙、美国等国家更是超 15%^[1]。但风力发电存

在一个明显问题，风的波动具有随机性和间歇性，造成风电场的发电量很难准确预测。这种不确定性会给能源输送和电网的电力平衡带来挑战，所以精准的发电量预测，对风电场的日常管理和运行至关重要。

目前风速预测主要有两种技术路线：一是基于历史风速数据的统计预测；二是基于风动力学的气象模型预测。

第一种方法在现有文献中已有不少应用案例^[2]。之所以

1. 华电（云南）新能源发电有限公司 云南昆明 650100

[6] He Pengfei, Hao J K, Xia Jinhui. Learning-guided iterated local search for the minmax multiple traveling salesman problem[J]. Computers & Operations Research, 2026, 185: 107255.

[7] Zheng Jiongzhi, Hong Yawei, Xu Wenchang, et al. An effective iterated two-stage heuristic algorithm for the multiple traveling salesmen problem[J]. Computers & Operations Research, 2022, 143: 105772.

[8] Park J, Kwon C, Park J. Learn to solve the min-max multiple traveling salesmen problem with reinforcement learning[C]// AAMAS'23: Proceedings of the 2023 International Conference on Autonomous Agents and Multiagent Systems. Richland, SC: IFAAMAS, 2023: 878-886.

[9] Son J, Kim M, Choi S, et al. Equity-transformer: solving NP-hard min-max routing problems as sequential generation with equity context[PP/OL].(2024-02-05)[2026-06-15].<https://doi.org/10.48550/arXiv.2306.02689>.

[10] Zuo Binbin, Li Weifan, Zhao Jiankuo, et al. CMIP: combining constructive model with improvement policy for large-scale min-max multiple traveling salesman problem[J]. IEEE Transactions on Intelligent Transportation Systems, 2025, 27(1): 1550-1564.

[11] Cordeau J F, Gendreau M, Laporte G. A tabu search heuristic for periodic and multi-depot vehicle routing problems[J]. Networks, 1997, 30(2): 105-119.

【作者简介】

徐若易（1994—），男，浙江舟山人，博士研究生，助教，研究方向：演化计算。

陈实（2005—），男，浙江嘉兴人，本科，研究方向：智能优化算法。

王麒向（2006—），男，浙江杭州人，本科，研究方向：智能优化算法。

（收稿日期：2026-05-16 修回日期：2026-06-18）

得到广泛应用, 主要是因为风电场能方便地获取可靠的历史数据, 这些数据可以用自回归模型、神经网络、支持向量机等多种统计模型来分析^[3]。这类方法能较好地估算月均及更长周期的风速, 但部分研究也将其用于短期风速预测^[4]。对于大多数短期预测场景来说, 大气动力学的影响是决定性的, 因此可靠的预测模型必须结合气象模型。气象模型通过近似求解控制大气动力学与热力学行为的一组物理方程来实现预报。气象模型主要分为三类: 全球模型, 主要考虑全球范围内的变量和相互作用, 输出低分辨率的预报结果; 中尺度模型, 分辨率最高可达 1 km; 局部模型, 能提供更高分辨率的预报。比如陈慧丽^[5]采用高分辨率有限区域模型, 开展了基于物理模型的短期风速预测研究; 祁卓平^[6]则尝试将全球物理气象模型的输出, 与神经网络、自回归模型相结合, 其研究表明, 神经计算方法的预测效果优于自回归模型。

本文将中尺度模型 (MM5)^[7] 与神经网络相结合, 构建了一套适用于风电场短期风速预测的稳健系统。具体而言, 将全球预报模型^[8]的输出结果, 结合部分大气探空的局地数据, 共同作为 MM5 模型的初始条件和边界条件。MM5 模型会对全球模型的数据进行物理降尺度, 从而得到小范围区域的风速预测结果。然后神经网络会处理 MM5 模型的输出及其他相关变量, 进而准确预测风电场内每台风力发电机的风速。在实验环节, 将这套混合系统应用于西班牙某风电场的风速预测, 取得了积极的验证结果。

1 算法介绍

本文提出的短期风速预测混合系统, 融合了天气预报模型和神经网络这类人工智能技术。系统的输入来自全球天气预报模型, 其输出会作为 MM5 模型的初始条件。整个流程包含两次降尺度过程: 第一次是 MM5 模型的物理降尺度, 第二次是神经网络的统计降尺度。

基于中尺度预报的短期风速预测需要多个步骤, 同时会用到国内外气象预报机构发布的各类数据。具体来说, MM5 模型的初始条件来自美国国家环境预测中心运行的全球预报系统^[9]。这套全球预报系统能生成全球任意位置、任意高度的未来气象信息, 水平覆盖范围为整个地球。通过求解控制大气动力学与热力学行为的纳维 - 斯托克斯方程来实现预报。模型会输出气压 (P)、温度 (T)、位势高度 (gph)、风速和风向 (V) 等一系列大气变量。这些变量的求解会在 1 000 hPa~10 hPa 之间的多个高度层上进行。

本文采用大气探空数据补充全球预报系统的数据, 必要时也可以加入 Metar 机场气象数据。基于初始和边界数据, 使用第五代中尺度模型 MM5 完成第一次降尺度处理。MM5

是一款有限区域模型, 同样求解大气动力学和热力学方程, 但不包含海洋 - 陆地相互作用等全球预报模型中的部分重要变量。并对辐射、水分相变、积云形成、行星边界层过程等多种大气过程进行了参数化处理。凭借出色的多功能性和可靠性, MM5 在此前 15 年里, 成为区域预报和中尺度大气行为分析领域应用最广泛的模型之一^[10]。MM5 模型的一个显著特点是支持不同积分区域的嵌套计算。本次研究中, 从全球模型约 111 km×78 km 的分辨率开始, 第一个积分在 45 km×45 km 的区域内完成。第二个积分区域嵌套在第一个区域内部, 分辨率为 15 km×15 km。第二个区域的积分计算, 会采用第一个积分区域输出的边界条件。所以在本次研究中, MM5 模型通过两步插值完成对全球数据的降尺度。这次物理降尺度得到的风速和风向预测结果, 比全球预报模型的输出更贴合实际地形。MM5 模型不仅能完成空间上的物理降尺度, 还能通过插值风速值实现时间降尺度, 得到逐小时的平均预测结果。

但 MM5 模型的输出无法完整覆盖风电场的全部区域, 本次研究中 MM5 的最高分辨率只有 15 km, 这一精度暂且达不到单台风机风速预测的要求。基于这一原因, 引入人工神经网络 (ANN) 来完成第二次降尺度。人工神经网络是一种大规模并行分布式信息处理系统, 已在大量非线性问题的建模中取得了成功应用。其基本处理单元是神经元, 具体模型如图 1 所示。ANN 通过构建输入与输出之间的映射关系, 从给定的样本数据中学习规律, 进而对未来样本做出预测。被认为是高精度的通用逼近器, 能够拟合绝大多数类型的函数。单隐藏层神经网络在预测和时间序列建模领域应用十分广泛^[11], 本文也采用了这种网络结构 (如图 2 所示)。




图 1 神经元模型

该网络包含输入层、隐藏层和输出层三层结构, 输出信号与输入信号的对应关系为:

$$y = \varphi \left(\sum_{j=1}^n w_j x_j - \theta \right) \quad (1)$$

式中： y 为输出信号， x_j ($j=1,2,\cdots,n$) 为输入信号， w_j 为第 j 个输入的权重。




图 2 神经网络的结构

逻辑函数：

$$\varphi(x)=\frac{1}{1+e^{-x}} \tag{2}$$

选取以下参数作为神经网络的输入 x ：风电场周边两个网格点的风速序列，以及其中一个点的风向和温度数据。这些数据都来自 MM5 模型对应高度的输出，考虑到风电场的地形条件，所有风机的安装高度基本一致。同时加入了两个时间序列作为输入变量，用来表征与大气环流密切相关的太阳周期。太阳周期用公式表示为：

$$S_1=\sin(H\frac{2\pi}{24}) \tag{3}$$

$$S_2=\cos(H\frac{2\pi}{24}) \tag{4}$$

式中： $H=[0, 23]$ 是整数向量。

通过以下步骤选择神经网络输入变量对应的两个网格点：先让 MM5 模型在 $15\text{ km}\times15\text{ km}$ 的网格上，输出多个高度特定点的预报结果。同时，风的中尺度预报会在不同预测点生成对应的相关变量。具体思路为找出距离风电场最近，且 MM5 风速序列与风电场同期逐小时平均风速相关系数最高的网格点。因为这些序列之间的相关性很强，平均风速能很好地筛选出与风电场高度处风速趋势最匹配的 MM5 网格点。经过对不同变量组合的多次测试，最终确定神经网络的最优输入变量集。神经网络的输出 y ，对应风力机未来 48 h 的实际风速测量值。采用经典的 Levenberg-Marquardt 算法来训练神经网络。对于输入神经网络的每一组数据，网络都会输出对应风机的风速预报结果。

2 结果与分析

本文将提出的混合预报系统，应用于东南部的一个风

电场短期风速预报。收集了这一风电场对应的全球模式数据、大气探测数据以及同期的 METAR 数据。为各类大气过程选择了对应的参数化方案：积云形成采用 Grell 方案，行星边界层采用 Blackadar 参数化，水分相变采用 Goodard 显式水汽方案，辐射过程采用 RRTM 长波方案。这些方案的选择，是基于提前用不同参数化组合运行 MM5 得到的分析结果。将 MM5 的不同输出结果与实测风场数据做了相关分析，结果显示这套参数组合下 MM5 模式的相关系数最高。经过数据筛选后，为每台风力机分别构建了包含 4 750 个样本的训练集，以及包含 1 570 个样本的验证集和测试集。继续用 Levenberg-Marquardt 算法训练网络，直到验证集误差开始上升时停止训练。因为该训练算法不具有确定性，所以对每台风力机都做了 50 次重复实验，只保留神经网络的最优结果。测试了隐藏层不同神经元数量的效果，表 1 为采用平均绝对误差（MAE）作为评价指标的实验结果。MAE 可以定义为：

$$MAE=\sum_{i=1}^N|x_i-y_i| \tag{5}$$

表 1 隐含层中不同数目神经元的 MAE

涡轮机 编号	神经元数量						
	9	10	11	12	13	14	15
1	1.852	1.875	1.835	1.850	1.859	1.870	1.904
2	2.001	2.024	1.984	1.999	2.008	2.019	2.053
3	2.010	2.033	1.993	2.008	2.017	2.028	2.062
4	1.795	1.818	1.778	1.793	1.802	1.813	1.847
5	1.526	1.549	1.509	1.524	1.533	1.544	1.578
6	2.001	2.024	1.984	1.999	2.008	2.019	2.053
7	1.664	1.687	1.647	1.662	1.671	1.682	1.716
8	1.653	1.676	1.636	1.651	1.660	1.671	1.705
9	1.662	1.685	1.645	1.66	1.669	1.680	1.714
10	1.785	1.808	1.768	1.783	1.792	1.803	1.837
11	1.632	1.655	1.615	1.63	1.639	1.650	1.684
12	1.751	1.774	1.734	1.749	1.758	1.769	1.803
13	1.761	1.784	1.744	1.759	1.768	1.779	1.813
14	1.752	1.775	1.735	1.750	1.759	1.770	1.804
15	1.853	1.876	1.836	1.851	1.860	1.871	1.905
16	1.695	1.718	1.678	1.693	1.702	1.713	1.747

所有结果均来自风电场 16 台风力涡轮机的测试集，对应隐藏层不同的神经元数量。从表中数据看出，MAE 值因风机而异，说明系统的预测能力会受到风机在风电场内位置的影响。隐藏层神经元数量的变化会对预测结果产生一定影响，调整神经元数量能观测到 MAE 的细微差异。图 3 展示了风电场所有风机预测误差（MAE 和 MSE）的频率分布直方图，从图中能直观看出误差的整体分布情况。




图3 频率分布直方图

网络训练完成后，可用其作未来48 h的风速预报。图4展示了测试集中某台风力涡轮机48 h的风速预测曲线。可以看到，混合系统预测的风速曲线与实测风速曲线贴合度很高。更重要的是，在所有测试案例中，预测系统都准确捕捉到了风速的变化趋势。基于所有风机的风速预测结果，能很方便地计算出整个风电场的发电量预测值。




图4 完整的预测实例

本文针对短期风速预报问题，提出了一种融合天气预报模型与人工神经网络的混合系统。该系统的主要创新点在于，将神经网络与全球、中尺度物理预报模型相结合，由神经网络完成最终的统计降尺度过程。搭建了包含神经网络在内的完整预测系统，并将其应用于风电场短期风速预测，取得了良好的实验效果。

参考文献:

- [1] 贾文星, 张小曳, 王宏, 等. 基于CUACE开发平流层化学模块并初步应用至全球数值天气预报模式系统GRAPES—GFS3.0[C]//中国气象学会. 第36届中国气象学会年会摘要集:S1 大气成分与碳中和, 以及大气成分与天气气候相互作用. 中国气象科学研究院大气成分与环境气象研究所, 2025:41.

所, 2025:41.

- [2] 邓小光. 基于深度学习神经网络在西南地区三维颠簸预报中的研究[C]//中国气象学会. 第36届中国气象学会年会摘要集:S13 人工智能助力气象高质量发展. 中国民用航空西南地区空中交通管理局贵州分局, 2025:86-89.
- [3] 王轩, 刘玉宝, 杜杰, 等. 一种用于将中尺度输出降尺度至LES模拟的U-LSGAN网络[C]//中国气象学会. 第36届中国气象学会年会摘要集:S13 人工智能助力气象高质量发展. 南京信息工程大学, 2025:97.
- [4] 秦昊宇, 张奥, 刘仕民, 等. MetMamba2: 物理约束的全球-区域统一气象建模框架[C]//中国气象学会. 第36届中国气象学会年会摘要集:S13 人工智能助力气象高质量发展. 北京弘象科技有限公司, 2025:82-85.
- [5] 陈慧丽. 基于混合优化模型风速预测的研究[D]. 兰州: 兰州大学, 2020.
- [6] 祁卓平. 基于神经网络的风速预测模型研究[J]. 自动化与仪表, 2023, 38(10):91-94.
- [7] 刘立夫. 基于参数优化和残差修正的短期风速预测[D]. 武汉: 武汉科技大学, 2024.
- [8] 何金徽. 基于时空多要素模型的风速预测[D]. 成都: 成都信息工程大学, 2023.
- [9] 张冰哲. 基于相关性分析与机器学习结合的风速预测方法研究[D]. 北京: 华北电力大学, 2022.
- [10] 关永锋. 基于自适应组合模型的短期风速预测研究[D]. 武汉: 武汉科技大学, 2022.
- [11] 王庆改, 何友江, 梁鹏, 等. MM5和WRF模式对高空气象数据模拟的对比分析[J]. 安全与环境学报, 2014, 14(1): 278-284.

【作者简介】

曾昌学(2000—), 男, 四川乐山人, 专科, 助理工程师, 研究方向: 集控中心运行。

(收稿日期: 2025-12-09 修回日期: 2026-07-13)