文章编号:1001-2060(2024)04-0147-07

# 基于时程数据的翼型尾流特征识别模型分析

赵凯程,李 春,缪维跑,岳敏楠

(上海理工大学能源与动力工程学院,上海200093)

摘 要:针对传统流场分析方法难以提取非线性与高维度数据特征的问题,结合自适应噪声完全集合经验模态分解(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, CEEMDAN)与分形盒维数对速度、压力和 涡量等时程数据进行分解、筛选及重构,并结合深度学习建立尾流特征识别模型,以实现翼型特征和流动攻角的反 向预测。结果表明:当训练集和测试集数据来自同一翼型时,所提模型对流动攻角的识别率最高可达 98.8%,当数 据来自不同翼型时,准确率仍可达 95.6%,验证了所提模型的准确性、可行性及泛化性。

关键 词:尾流;特征提取;深度学习;分形盒维数

中图分类号:TK83 文献标识码:A DOI:10.16146/j.cnki.rndlgc.2024.04.018

[引用本文格式] 赵凯程,李 春,缪维跑,等. 基于时程数据的翼型尾流特征识别模型分析[J]. 热能动力工程,2024,39(4):147-153. ZHAO Kai-cheng, LI Chun, MIAO Wei-pao, et al. Analysis of wingtip vortex characteristics based on time history data using a feature recognition model[J]. Journal of Engineering for Thermal Energy and Power,2024,39(4):147-153.

# Analysis of Wingtip Vortex Characteristics based on Time History Data Using a Feature Recognition Model

ZHAO Kai-cheng, LI Chun, MIAO Wei-pao, YUE Min-nan

(School of Engergy and Power Engineering, University of Shanghai for Science and Technology, Shanghai, China, Post Code: 200093)

**Abstract**: Addressing the challenge of recognizing nonlinear and high-dimensional data features in traditional flow field feature extraction methods, we optimized the complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN) and fractal box dimension methods to decompose, filter, and reconstruct time history data such as velocity, pressure and vorticity. By combining this approach with deep learning, a wake feature recognition model was established to achieve reverse prediction of airfoil characteristics and flow attack angles. The results demonstrate that when the training and test datasets are derived from the same airfoil, the recognition accuracy of the proposed model to the flow attack angle can reach up to 98.8%; when the data originates from different airfoils, the recognition accuracy can be as high as 95.6%, verifying the accuracy, feasibility and generalizability of the proposed method. **Key words**; wake, feature extraction, deep learning, fractal box dimension

引 言

近年来,随着能源需求规模增加和能源安全意

Fund-supported Project: National Natural Science Foundation of China (51976131, 52006148)

识的不断加强,发展清洁能源受到各界人士的广泛 关注。风能作为一种无污染、可循环利用的绿色能 源,其开发利用对社会可持续发展具有重要 意义<sup>[1]</sup>。

收稿日期:2023-02-27; 修订日期:2023-04-10

**基金项目:**国家自然科学基金资助项目(51976131,52006148)

作者简介:赵凯程(1999-),男,上海理工大学硕士研究生.

通信作者:李 春(1963-),男,上海理工大学教授.

2024 年

风力机作为高效的风能捕获装置,其叶片攻角 会显著影响风能利用效率,小攻角时无法从流场中 获取足够的能量,而攻角过大易导致流体绕流翼型 表面时发生流动分离,造成升力骤降和阻力剧增,严 重影响风力机运行稳定性<sup>[2]</sup>。因此,如何准确有效 地获取叶片旋转过程中的攻角,从而为后续变桨等 操作提供便利成为亟待解决的问题。当前风力机设 备正朝大型化与集成化方向发展,其叶片长度逐渐 递增,尾流的流动特征愈发复杂。在风力机设计研 究中,分析其翼型攻角与流动特征机理的研究具有 重要意义<sup>[3]</sup>,对尾流特征的提取与分析有助于优化 翼型的气动性能<sup>[4]</sup>。

由于传感器自身体积会干扰流场流动特性、风 场流动受外界随机扰动因素干扰较大等原因,在实 际风场中对特征数据的提取较为困难<sup>[5]</sup>,造成目前 流场的分析数据大多来源于计算网格的模拟<sup>[6]</sup>。 因计算网格的快照信息数据量极为复杂庞大,受限 于计算资源不足以及算法精确度不足对快照信息直 接进行特征提取具有一定的难度<sup>[7]</sup>。

Robert<sup>[8]</sup>结合绝对最小值收敛与选择算子方法 (Least Absolute Shrinkage and Selection Operator, LASSO),虽然可以实现对流场中线性特征的有效识 别,但针对非线性特征的提取效果欠佳。江昊等 人<sup>[9]</sup>提出一种数据驱动的流场特征识别模型,该模 型使用基于非线性动力学偏微分方程函数识别方法 (Partial Differential Equation Functional Indentification of Nonlinear Dynamics, PDE-FIND)对考虑非线性特 征的流场实现有效识别,但泛化性能欠佳,仅适用于 特定的微分方程。

近年来,针对基于深度学习对流场时程数据特 征提取的研究颇受重视。Zuo 等人<sup>[10]</sup>采用了一种 基于卷积神经网络与多层感知器的数据驱动方法, 可有效预测翼型周围不可压缩稳态流场及其气动系 数,较好地验证了深度学习在流场特征提取领域的 适用性和可行性。

对于复杂流场时程数据进行降维不仅可降低数 据维度和数量,而且更利于提取有效的数据特征。 邱亚松<sup>[11]</sup>通过降维模型对复杂流场数据进行处理, 并改进奇异值分解(Singular Value Decomposition, POD)两种典型的方法,提出一种流场本征维 度特征数的计算方法,该方法可有效减少计算量并 显著提高特征提取效率。战庆亮等人<sup>[12]</sup>提出一种 基于流场时程数据的特征识别方法,通过无监督自动编码器提取流场时程数据的低维表征,利用深度 学习挖掘流动特征,可有效识别流动的分离区,表明 深度学习与降维处理结合的可行性。

针对流场数据处理计算量过大和非线性特征难 以提取的问题,本文结合深度学习与降维处理方法 提出一种基于翼型尾流时程数据的流动特征识别模 型,并对翼型尾流时程数据使用深度学习方法,有效 实现了流动特征的提取和降维处理,建立了识别模 型并验证了其有效性和可靠性,为相关研究提供了 一种可行的思路和方法。

#### 1 流场数据

#### 1.1 基础翼型

选取 NACA0012、NACA0015、NACA0018 和 NACA0021 作为数值模拟的翼型。在模拟中设定翼 型弦长 *c* 为 0.1 m,4 种翼型几何轮廓如图 1 所示。



图1 四种基准翼型示意图

#### Fig. 1 Schematic diagram of four basic airfoil profiles

以 0°,5°,10°,15°,20°和 25°为入流攻角,对 4 种不同厚度翼型进行数值模拟。图 2 为翼型不同入 流攻角示意图。



1.2 计算域及网格划分

计算域及边界条件如图3所示。整个计算域由

两部分组成,分别为外流域和叶片旋转域。流域尺 寸为36c×24c,入口设置为速度进口,出口设置为 压力出口。速度入口的水平速度为10 m/s,垂直方 向速度分量为0 m/s。湍流粘度比为10,流域的介 质密度为1.18 kg/m<sup>3</sup>,动力粘度为1.86×10<sup>-5</sup> kg/(m·s)。



图 3 计算域及边界条件

Fig. 3 Computational domain and boundary condition

图 4 为计算域网格及翼型边界层网格。为保证 尾流流程数据模拟的精度,对近尾流区域与扰流区 域的网格进行加密。加密网格区域由 1 个横向长度 为 12c、纵向长度为 10c 的矩形和 1 个半径为 5c 的半 圆形组成。旋转域区域半径为 R1,其旋转中心距流 场上边界 12c、距速度进口 12c,并且在探测点分布 的尾流位置也进行加密以确保测点数据的可靠性。



图 4 流体域网格结构 Fig. 4 Fluid domain grid structure

## 1.3 数据集来源

通过在 STAR-CCM<sup>+</sup>中设置衍生零部件的方式 在流场的尾流区域设置 121 个探测点。探针会计算 并保存所处点的瞬时速度、瞬时涡量和瞬时压力。 网格计算的时间步长为0.0005s,探针每两个时间 步长导出一次数据,即时程数据的时间步长为 0.001s。每个流场在处于稳定后计算1×10<sup>4</sup>步数 据,共保存1.815×10<sup>6</sup>个数据。

# 2 时程数据与特征识别模型的建立

#### 2.1 时程数据

选用流场的时程数据作为原始数据进行流场特征识别,单个测点的时程数据可反映出该测点的流动物理特性随时间变化情况,包含有多个测点的时程数据集则可反映出流场的整体流动特征。

当攻角为25°时,流场趋于平稳状态下测点处的压力、涡量及速度的时程曲线如图5所示。



# 图 5 攻角 25°时的时程曲线

Fig. 5 Time history curves at  $25^{\circ}$  angle of attack

#### 2.2 时程数据的预处理

流场尾流时程数据在流动中受绕流体的形状、 运动速度、流体粘性和密度等因素影响,呈现复杂紊 乱的状态<sup>[13]</sup>。而流场中涡流的相互作用以及涡旋 的合并、分裂、扭曲、摆动等也可导致时程数据的不 确定性增大<sup>[14]</sup>。因此亟需对时程数据进行预处理, 以提高所提模型的识别性能。

CEEMDAN 算法是一种基于经验模态分解 (Empirical Mode Decomposition, EMD)的信号处理 方法,可将复杂信号分解成多个固有模态函数(Intrinsic Mode Function, IMF)。其步骤为:对原始信 号进行扩展,生成1组白噪声并加入到信号中;通过 EMD 对带噪声的信号进行分解,将分解得到的固有 模态函数与白噪声进行协同降噪处理;重复此过程 直到满足停止准则,最后得到1组经过筛选降噪后 的固有模态函数,有效提取了信号在不同频率和时 间尺度上的振动分量<sup>[15]</sup>。与传统 EMD 不同, CEEMDAN 可以有效避免模态混叠问题的出现<sup>[16]</sup>。

循环两次添加白噪声并进行协同降噪处理是模型中 CEEMDAN 的停止准则,停止信号分解后以分 形盒维数为筛选指标对得到的7组固有模态函数信 号进行筛选。分形盒维数可以识别和分类具有不同 特征的信号,并且可对信号特征的丰富程度进行量 化。信号携带的特征丰富程度与分形盒维数呈负相 关,故本文选取分形盒维数最小的固有模态函数为 特征信号。图6为结合 CEEMDAN 与深度学习的流 动特征识别流程图。







# 2.3 流动特征识别模型

深度学习是流场特征提取研究的热门方向,而 卷积神经网络(Convolutional Neural Networks, CNN)则是深度学习领域最常用的工具。故本文利 用 CNN 模型进行流场特征识别与分类。

CNN 模型中包含 5 个交替的卷积层与池化层 以及 1 个全连接层,以 Softmax 为分类器。在训练 中,设置迷你批次处理的大小为 32,且在每一训练 周期开始时对数据集进行随机排序以避免模型过度 拟合。经预处理后的尾流时程数据按 8:1:1的比例 随机分为训练集、验证集与测试集。卷积神经网络 各层的具体参数如表 1 所示。

#### 表1 卷积神经网络具体参数

Tab. 1 Specific parameters of convolutional neural network

网络层	卷积核大小	卷积核	输出
卷积层1	[11 × 1]	16	510 × 1
池化层1	[2×1]	16	255 × 1
卷积层2	[5×1]	32	126 × 1
池化层2	[2×1]	32	63 × 1
卷积层3	[3 × 1]	32	61 × 1
池化层3	[2×1]	32	$30 \times 1$
卷积层4	[2×1]	64	29 × 1
池化层4	[2×1]	64	$14 \times 1$
卷积层5	[2×1]	128	13 × 1
池化层5	[2×1]	128	6 × 1
全连接层	-	-	4

注:表中"-"表示无卷积核。

## 3 结果与分析

#### 3.1 不同优化器对模型性能的影响

在深度学习神经网络中,不同优化器对于算法 性能有着重要的影响,不仅会干扰网络的收敛速度 和准确率,还会干预过拟合的判定。为了进一步探 究优化器对模型整体性能的影响程度,本文采用 Adam,Sgdm 和 Rmsprop 3 种常用优化器进行验证。 损失和准确率的迭代曲线如图 7 所示。由图 7 可 知,在收敛速度上,Rmsprop 最快,在约 60 次迭代后 可达 97% 以上的准确率;Adam 的收敛速度次之,在 约 90 次迭代后可以达到 97% 的准确率;而 Sgdm 较 为缓慢,需要在 140 次迭代后才能达到 97% 以上的 准确率。在损失率上, Rmsprop 优于 Adam, 但其整体稳定性逊于 Adam。为此,综合考虑收敛速度、损失和整体稳定性, Adam 是整体性能最优的算法, 故后续研究中将其作为特征识别模型的优化器。





## 3.2 流动特征分析

通过 CNN 对预处理后的时程数据集进行训练, 得到尾流测点时程数据与翼型入流攻角的映射关 系,较好地实现了对入流攻角的分类和预测。图 8 为该特征识别模型在翼型不变而流动攻角改变的情 况下,通过时程数据反向识别翼型准确率的结果。 由图 8 可知,在低攻角情况下,3 种时程数据的反向 预测准确率均不理想。这可能是由于在流动攻角较 小时,流动比较平稳,流体粘性效应占主导地位,形 成流速分层现象,该状态致使尾流中的涡旋结构较 为简单且相对稳定,从而导致获取的时程数据不易 出现大幅波动,神经网络中出现梯度消失的问题。 当攻角大于 10°时,3 种时程数据的识别准确率均可 达 80% 以上,且涡量时程数据的识别结果最为理 想,最高可达 98.8%,体现该模型具有较好的识别 性与可行性。





Fig. 8 Accuracy results of three reverse identification methods for time history data

#### 3.3 变训练集交叉验证

在实际工程中,受限于测量仪器精度与自身体 积干扰影响,时程尾流数据的测量与采集存在较大 局限性。而特征识别模型仅能使用有限的时程数据 进行训练,无法兼顾所有工况。

为此,选取不同工况下的训练集和验证集数据 交叉验证该识别模型的泛用性。将4种不同翼型时 程数据分别作为训练集,同时分别将4种不同翼型 的时程数据作为验证集,达到变训练集交叉验证的 效果。当低攻角下较低识别准确率的数据与高攻角 工况下数据交叉训练时,整体数据准确率会降低而 失去了交叉训练的意义,故仅取高攻角工况下的时 程数据进行训练与验证。图9为以涡量时程数据为 变训练集时的交叉验证直方图。



varying training sets

由图 9 可知,当训练集与验证集的时程数据来 源于同一绕流部件时,模型的识别准确率可达 96% 以上。而当训练集与验证集来源不一致时,识别的 准确率有所下降,但仍然维持在一个较高的水平。 尤其是以 NACA0015 的时程数据作为训练集时,各 验证集均可达到 92% 的准确率,较好地验证了该模 型的泛化性能。

#### 4 结 论

因传统特征提取方法对流场非线性特征提取具 有一定局限性,本文基于流场数据降维处理与深度 学习方法构建了一种流场特征识别模型,并通过不 同工况下的时程数据较好地验证了该模型的可行 性,结论如下:

(1)提取流场尾流处不同位置的时程数据作为 数据集,通过CEEMDAN算法对数据进行重构分解, 以分形盒维数作为指标对固有模态函数进行筛选, 实现对流场时程数据的预处理。

(2)以Adam为优化器,构建了一个卷积神经网络。当翼型不变而流动攻角改变时,该流动特征 识别模型有较高的识别准确率。攻角在10°以上时,模型的识别准确率达到98.8%,并发现涡量时 程数据的识别准确率最高。

(3)当训练集与验证集数据来源于不同部件 时,模型准确率仍可达到 95.6%,通过交叉验证表 明了所提模型具有良好的泛化性能。

#### 参考文献:

- [1] 左 然,徐 谦,杨卫卫.可再生能源概论[M].北京:机械工 业出版社,2021.
   ZUO Ran,XU Qian,YANG Wei-wei. Introduction to renewable energy[M]. Beijing:China Machine Press,2021.
- [2] 张所续,马伯永.世界能源发展趋势与中国能源未来发展方向
   [J].中国国土资源经济,2019,32(10):20-27,33.
   ZHANG Suo-xu, MA Bo-yong. Development trend of world energy

and future development directions of China's energy [J]. Natural Resource Economics of China,2019,32(10):20-27,33.

[3] 王晓宇,赵夏青,许炳坤,等.风力机组风速仪测量风速与来流风速校正研究[J].分布式能源,2019,4(3):63-68.

WANG Xiao-yu, ZHAO Xia-qing, XU Bing-kun, et al. Correction of wind speed measurement and inlet wind speed by wind turbine anemometer[J]. Distributed Energy, 2019, 4(3):63-68.

- [4] BEN ALI J, FNAIECH N, SAIDI L, et al. Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals [J]. Applied Acoustics, 2015, 89:16 - 27.
- [5] 李 春,叶 舟,高 伟,等. 现代陆海风力机计算与仿真
  [M].上海:上海科学技术出版社,2012.
  LI Chun,YE Zhou,GAO Wei, et al. Computation and simulation of modern land-sea wind turbine [M]. Shanghai: Shanghai Scientific & Technical Publishers,2012.
- [6] GORDON G, ROBERT F, ANTONIJA H, et al. Calibration and verification of operation parameters for an array of Vectrino profilers configured for turbulent flow field measurement around bridge piers—Part I[J]. Fluids, 2022, 7(10):315 – 332.
- [7] 许子非,缪维跑,李 春,等. 流场非线性特征提取与混沌分析
  [J].物理学报,2020,69(24):338-346.
  XU Zi-fei, MIAO Wei-pao,LI Chun, et al. Nonlinear feature extraction and chaos analysis of flow field [J]. Acta Physica Sinica, 2020,69(24):338-346.
- [8] ROBERT T. Regression shrinkage and selection via the Lasso[J]. Journal of the Royal Statistical Society: Series B (Methodological),2018,58(1):273-282.
- [9] 江 吴,王伯福,卢志明.基于数据驱动的流场控制方程的稀疏识别[J].力学学报,2021,53(6):1543-1551.
  JIANG Hao,WANG Bo-fu,LU Zhi-ming. Data-driven sparse identification of governing equations for fluid dynamics [J]. Chinese Journal of Theoretical and Applied Mechanics, 2021, 53(6): 1543-1551.
- [10] ZUO Kui-jun, BU Shu-hui, ZHANG Wei-wei, et al. Fast sparse flow field prediction around airfoils via multi-head perceptron based deep learning architecture [J]. Aerospace Science and Technology, 2022, 130:107942.
- [11] 邱亚松.基于数据降维技术的气动外形设计方法[D].西安: 西北工业大学,2014.
   QIU Ya-song. Aerodynamic shape design methods based on data

dimension reduction approaches [D]. Xi'an; Northwestern Poly-technical University, 2014.

[12] 战庆亮,白春锦,张 宁,等. 基于时程卷积自编码的机翼绕流特征识别方法[J]. 航空学报,2022,43(11):435-443.
ZHAN Qing-liang, BAI Chun-jin, ZHANG Ning, et al. Feature extraction method of flow around airfoil based on time-history convolutional autoencoder[J]. Acta Aeronautica et Astronautica Sinica,2022,43(11):435-443.

LI Zuo-wu, HE De-xin. Reviews of fluid dynamics researches in wind energy engineering [ J ]. Advances in Mechanics, 2013, 43(5):472-525.

[14] 田琳琳.风力机尾流数值模拟及风电场机组布局优化研究[D].南京;南京航空航天大学,2014.

TIAN Lin-lin. Numerical simulation of wind turbine wakes and the study of wind farm layout optimization [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2014.

[15] 孙 康,岳敏楠,金江涛,等.基于改进变分模态分解与流形 学习的滚动轴承故障诊断[J].热能动力工程,2022,37(3);

#### (上接第146页)

- [11] BENGIO Y, SIMARD P, FRASCONI P. Learning long-term dependencies with gradient descent is difficult [J]. IEEE Transactions on Neural Networks, 1994, 5(2):157 - 166.
- [12] HOCHREITER S, SCHMIDHUBER J. Long short-term memory
   [J]. Neural Computation, 1997, 9(8):1735 1780.
- [13] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. arXiv,2017.
- [14] ZHOU Hao-yi, ZHANG Shang-hang, PENG Jie-qi, et al. Informer: Beyond efficient transformer for long sequence time-series forecasting[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(12):11106-11115.
- [15] LIM B,ZOHREN S. Time series forecasting with deep learning: A survey[J]. Philosophical Transactions of the Royal Society A,

176 – 185.

SUN Kang, YUE Min-nan, JIN Jiang-tao, et al. Fault diagnosis of rolling bearing based on improved variational mode decomposition and manifold learning [J]. Journal of Engineering for Thermal Energy and Power, 2022, 37 (3):176 – 185.

[16] 肖俊青,金江涛,李 春,等. 基于优化 CEEMDAN-CNN 的轴 承故障诊断研究[J]. 热能动力工程,2022,37(4):166-174.
XIAO Jun-qing, JIN Jiang-tao, LI Chun, et al. Research on bearing fault diagnosis based on optimized CEEMDAN-CNN[J]. Journal of Engineering for Thermal Energy and Power,2022,37(4): 166-174.

(刘 颖 编辑)

#### 2021,379(2194):20200209.1-20200209.14.

- [16] YANG Shao-bo, DENG Ze-gui, LI Xing-fei, et al. A novel hybrid model based on STL decomposition and one-dimensional convolutional neural networks with positional encoding for significant wave height forecast[J]. Renewable Energy, 2021, 173:531 – 543.
- [17] SMYL S. A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting[J]. International Journal of Forecasting, 2020, 36(1):75-85.
- [18] HUANG Xiao-qiao, LI Qiong, TAI Yong-hang, et al. Time series forecasting for hourly photovoltaic power using conditional generative adversarial network and Bi-LSTM [J]. Energy, 2022, 246: 123403.1 – 123403.13.

(刘 颖 编辑)