

## 基于深度学习的流场时程特征提取模型

战庆亮 葛耀君 白春锦

## Flow feature extraction models based on deep learning

Zhan Qing-Liang Ge Yao-Jun Bai Chun-Jin

引用信息 Citation: *Acta Physica Sinica*, 71, 074701 (2022) DOI: 10.7498/aps.71.20211373

在线阅读 View online: <https://doi.org/10.7498/aps.71.20211373>

当期内容 View table of contents: <http://wulixb.iphy.ac.cn>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 流场非线性特征提取与混沌分析

Nonlinear feature extraction and chaos analysis of flow field

物理学报. 2020, 69(24): 249501 <https://doi.org/10.7498/aps.69.20200625>

#### 基于深度学习的相位截断傅里叶变换非对称加密系统攻击方法

Attacking asymmetric cryptosystem based on phase truncated Fourier transform by deep learning

物理学报. 2021, 70(14): 144202 <https://doi.org/10.7498/aps.70.20202075>

#### 基于深度学习的光学表面杂质检测

Deep-learning-assisted micro impurity detection on an optical surface

物理学报. 2021, 70(16): 168702 <https://doi.org/10.7498/aps.70.20210403>

#### 基于深度学习的新混沌信号及其在图像加密中的应用

A new chaotic signal based on deep learning and its application in image encryption

物理学报. 2021, 70(23): 230502 <https://doi.org/10.7498/aps.70.20210561>

#### 基于深度学习压缩感知与复合混沌系统的通用图像加密算法

General image encryption algorithm based on deep learning compressed sensing and compound chaotic system

物理学报. 2020, 69(24): 240502 <https://doi.org/10.7498/aps.69.20201019>

#### 基于深度学习的联合变换相关器光学图像加密系统去噪方法

In depth learning based method of denoising joint transform correlator optical image encryption system

物理学报. 2020, 69(24): 244204 <https://doi.org/10.7498/aps.69.20200805>

## 基于深度学习的流场时程特征提取模型\*

战庆亮<sup>1)†</sup> 葛耀君<sup>2)</sup> 白春锦<sup>1)</sup>

1) (大连海事大学交通运输工程学院, 大连 116026)

2) (同济大学, 土木工程防灾国家重点实验室, 上海 200092)

(2021 年 7 月 25 日收到; 2021 年 12 月 8 日收到修改稿)

特征识别是流体力学的重要研究方向, 然而在中高雷诺数情况下物体的尾流流场复杂, 难以通过传统方法实现特征的提取与识别. 深度学习理论与技术的不断发展为复杂流场特征的识别提供了新方法. 基于流场时程数据的深度学习模型, 本文研究了 4 种模型对尾流场特征提取与识别的精度, 得到了针对流场时程特征提取的高精度新方法. 结果表明: 所提出的模型能够识别尾流物理时程的不同特征, 并通过流场时程实现了目标的外形识别, 验证了方法的可行性; 同时结果表明基于卷积运算的深度学习模型精度高, 适用于流场时程数据的特征分析; 深度学习网络结构更深、层间结构复杂的残差卷积网络识别精度最高, 是尾流时程分析的高精度算法. 本文所提方法从流场物理量时程的角度对流场特征进行了提取与识别, 证明了深度学习方法具有较高的识别精度, 是研究流场特征的重要途径.

**关键词:** 流场特征提取, 深度学习, 流场时程, 残差卷积网络, 特征识别**PACS:** 47.10.Fg, 47.11.-j, 47.85.-g**DOI:** 10.7498/aps.71.20211373

## 1 引言

特征识别是流体力学研究中非常重要且具有挑战性的一类问题<sup>[1]</sup>, 现有方法多采用局部物理量及其量值进行识别. 例如涡的识别方法包括基于涡量的识别<sup>[2]</sup>、基于  $Q$  准则的识别和基于 Liutex 向量<sup>[3]</sup>的识别方法等. 这些方法依赖主观选择特定的参数并确定其阈值, 过程受主观因素影响大且泛化能力弱. 同时, 中、高雷诺数条件下流场的复杂性限制了传统特征工程在流场特征识别领域的应用.

近年来, 深度学习理论与应用发展为流体力学问题研究提供了新的方法与视野<sup>[4,5]</sup>. 如基于人工智能方法的流场网格划分方法<sup>[6]</sup>、基于数据驱动的神经网络雷诺应力模型<sup>[7,8]</sup>、涡振流场的深度学习

控制方法<sup>[9]</sup>、尾流状态的控制方法<sup>[10]</sup>、高精度流场的重构与预测<sup>[11]</sup>、基于深度学习的流动状态识别模型<sup>[12]</sup>等.

在流动的特征识别方面深度学习方法也取得了一定的进展, 如 Han 等<sup>[13]</sup>建立了流线和流面特征降维的深度学习框架 FlowNet, 同时实现了流场的可视化. Liu 等<sup>[14]</sup>建立了 ShockNet 深度学习方法, 实现了流场中激波的自动识别, 且计算速度和识别精度有了较大提升. Zhang 等<sup>[15]</sup>采用深度学习实现了基于两相流识别, 精度达到 94% 以上且计算速度快. Strfer 等<sup>[16]</sup>提出了基于图像的流场特征识别方法, 得到了基于数据驱动的识别方法, 具有好的泛化性且对未知特性的检测方面比基于物理准则的识别方法具有更大优势. Murata 等<sup>[17]</sup>用深度学习对瞬态流场进行模态分解, 得到了比传统模态分解精度更高的结果. Omata 和 Shiray-

\* 国家自然科学基金 (批准号: 51778495, 51978527)、桥梁结构抗风技术交通行业重点实验室 (上海) 开放课题 (批准号: KLWRTBMC21-02) 和辽宁教育厅研究计划 (批准号: LJKZ0052) 资助的课题.

† 通信作者. E-mail: zhanqingliang@163.com

ama<sup>[18]</sup> 提出了基于自编码模型的瞬态流固耦合分析方法, 同样采用数据驱动的方案得到了流场的低维表示. Kai 等<sup>[19]</sup> 提出了一种定制的基于卷积神经网络的自动编码器, 称为分层自动编码器, 它允许我们提取流场的非线性自动编码模式, 同时保持潜在向量的贡献顺序. 以上研究多针对流场快照进行研究, 相比于全场测量, 一点位置处流场信息的获取是方便且可靠的, 如一点的速度信号、压力信息等. 其缺点是相比于整个流场的瞬时信息, 一点处的流场信息极其有限, 采用传统的数学物理方法仅仅通过一点处的信号进行整个流场特征的推测极其困难.

另一方面, 由于结构复杂、层数更深的神经网络对非线性特征提取与表达的能力更强, 为复杂流动问题的研究提供了新的可能. 然而“更深”的网络必须要克服梯度弥散问题, 深度残差网络是目前较为成功的方法之一<sup>[20]</sup>, 不仅具有可信的精度和良好的收敛性, 训练也相对更加简化. 在图像识别领域, 基于深度残差网络构架结合卷积网络是性能提升的核心方法<sup>[21]</sup>, 同时也逐渐应用于众多其他领域, 如用于城市声音识别的可变形特征图残差网络<sup>[22]</sup>, 以及针对转捩问题提出的基于数据驱动的深度残差网络<sup>[23]</sup>等.

综上, 深度学习是复杂流场特征提取问题的一种极具潜力的解决方法, 而目前对基于时程数据的特征分析鲜有研究. 本文针对上述问题提出了基于流场中物理量时程数据的特征分析方法, 建立了4种不同结构的流场时程数据深度学习模型, 实现信号中抽象特征的提取与识别.

## 2 物理量时程特征提取的深度学习模型

合理的深度学习模型能够准确地表达输入映射到隐层的特征, 并通过迭代训练自动提取样本的关键特征. 本文的研究方法如图1所示, 首先通过数值模拟得到不同棱柱尾流处的时程数据集, 根据样本所属不同棱柱流场定义流场的特征标签; 然后将数据集分为训练集与测试集, 对训练集的样本进行深度学习模型有监督训练, 使得模型的输出特征标签与已知的标签接近; 进一步, 输入测试集的样本, 检验模型输出的流场特征标签与真实标签是否一致, 得到模型对不同特征的提取精度结果. 本文

对不同结构的深度学习模型进行了研究, 分别采用以下4种不同结构的模型对流场物理量时程中包含的特征进行提取与识别.

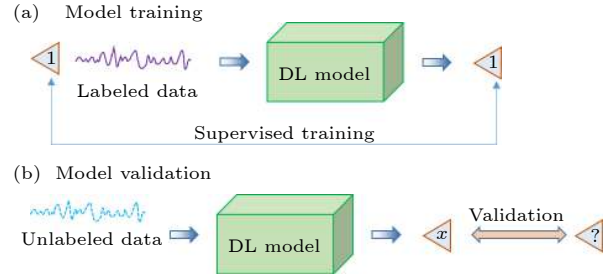


图1 特征提取方法

Fig. 1. Feature extraction methodology.

### 2.1 全连接网络 (multi-layer perceptron, MLP)

全连接网络又称多层感知网络, 是最简单、应用最广泛的深度学习模型, 其特点是任意层的神经元与上一层的所有神经元都是相连的, 这些相连的关系称为权重. 通常情况下, 输入与输出的变换关系可表示为

$$y_i^{n+1} = \sum_{j=1}^k F_{ij}^n a_j^n + b_i^n, \quad (1)$$

式中  $y$  为第  $n$  层全连接层的输出,  $F$  和  $b$  为第  $n$  层全连接层的权重和偏移矩阵. 从其结构原理可以发现, 每一个神经元都与上层的各神经元相关, 这将导致时程数据的每一个元素与上一层中其他元素的关系是完全等价的, 丢失了时程数据中各个时刻前后之间的关系. 同时, 在全连接层前增加 Dropout 层, 用来防止训练过程中的过拟合<sup>[24]</sup>, 保证模型的收敛.

### 2.2 时程卷积网络 (time convolutional neural network, TCNN)

卷积神经网络模仿了生物视觉的认知机制<sup>[25]</sup>, 已成功应用于图像识别、语音特征提取等领域, 通过建立特征提取模块提取输入数据的特征. 卷积神经网络通常包括输入层、卷积层、池化层和最后的全连接层. 卷积层通过卷积核对输入信号进行卷积操作, 是特征提取的主要计算步骤. 为了适应流场中物理量时域信号的一维特性, 本文采用一维卷积构建了可用于流场数据深度学习的时间卷积神经网络模型, 卷积层的运算如下式:

$$\text{Cov}(x) = \sum_{a=0}^m F(a) \times G(x-a), \quad (2)$$

式中  $F$  为权重向量,  $G$  为输入时程,  $m$  为卷积核大小,  $x$  为当前时刻位置,  $a$  为向量索引. 经过多个卷积核的卷积可分解出时程的多维特征, 通过池化层减少参数数量. 本文直接采用最大池化层将局部的最大值进行选择保留, 表达式如下:

$$P = \max_w \{A^l\}, \quad (3)$$

式中,  $P$  为池化层的输出,  $l$  为池化宽度,  $A$  为上层网络的特征矩阵,  $w$  为池化计算的局部范围大小. 在卷积网络中同样会用到全连接层, 其作用是将卷积层获得的特征平铺为向量形式, 便于通过 Softmax 变化成标签的对应关系, 起到承上启下的作用, 相




图 2 时间卷积网络结构示意图

Fig. 2. Structure of time convolution neural network.




图 3 全卷积网络结构示意图

Fig. 3. Structure of Fully connected convolution neural network.

当于在提取的高层特征向量上进行线性组合并且输出最后的预测结果. 整体网络结构如图 2 所示.

## 2.3 完全卷积网络 (fully convolutional neural network, FCNN)

基于时序数据的完全卷积网络由 Wang 等<sup>[26]</sup>提出, 不采用局部池化, 保留了更多的训练参数和特征, 是一种更“复杂”的深度学习训练方法, 本文采用的完全卷积网络结构如图 3 所示. 通过归一层<sup>[27]</sup>将每个神经元的输入分布调整到标准的正态分布, 避免梯度弥散, 保证计算的收敛速度. 激活函数可以对层输出结果进行非线性变换, 从而提升网络的表达能力. 整个网络共有 3 部卷积循环, 而后连接全局最大池化层和全连接层变换到对应的特征标签.

## 2.4 深度卷积残差网络 (residual convolutional neural network, RCNN)

深度残差网络<sup>[28]</sup>是图像识别研究的重要突破, 极大提高了深度学习网络的深度与精度. 由于网络的深度对模型的性能至关重要, 因此增加网络层数可实现更加复杂的特征提取. 然而当网络增加到一定层数后, 容易出现梯度消失导致模型无法收敛. 残差网络在卷积计算后加入跨层连接, 通过这样的线性快捷连接减少误差反向传播路径, 保证模型训练的收敛性. 本文构建了适用于流场时程数据的 RCNN 网络, 如图 4 所示, 该网络由 3 个残差块组成, 每个残差块包含 3 个卷积层.






图4 残差卷积网络结构示意图

Fig. 4. Structure of residual convolution neural network.

### 3 流场模拟与时程数据提取

选取三棱柱、方柱和六棱柱, 共计 3 种不同外形的棱柱流场时程数据集作为对象, 研究 4 种深度学习模型对流场特征的提取与识别效果. 定义三棱柱流场标签为 1, 方柱流场特征标签为 2, 六棱柱的流场特征标签为 3. 流场整体计算域如图 5 所示, 流向方向  $40D$ , 横向长度  $40D$ , 展向长度  $4D$ , 其中  $D$  为流场中棱柱体的平面特征长度. 棱柱上游来流区域流向长度  $10D$ , 下游区域流向长度为  $10D$ , 展向方向的网格数 20 层. 来流速度  $U_{\infty} = 1 \text{ m/s}$ ,  $Re_D = 6.8 \times 10^4$ , 在远离圆柱的流场区域使用较稀疏的网格, 而近尾流区采用较密的网格保证模拟结果可捕捉到较大尺度的尾流结构特征.




图5 整体计算域及平面网格划分

Fig. 5. Global computational domain and plane grid settings.

流场的数值模拟采用自主开发的三维非结构网格的流体计算程序 zFlower 实现<sup>[29]</sup>, 使用非结构化网格对流场空间进行离散. 通过三维非定常计算求得各算例的三维流场时程数据集, 图 6 所示为计

算所得的瞬时流场压力云图与速度分布云图. 瞬态流场云图反映了不同棱柱体引起的流场尾流结构的差异, 可见流动特征具有明显差异, 然而这些复杂的湍流尾流难以通过解析方法及物理准则进行特征提取与识别.




图6 各形状棱柱的瞬态流场云图 (a) 三棱柱压力云图; (b) 方柱压力云图; (c) 六棱柱压力云图; (d) 三棱柱速度云图; (e) 方柱速度云图; (f) 六棱柱速度云图

Fig. 6. Transient wake contour of prisms with different shapes: (a) Pressure contour of triangular prism; (b) pressure contour of square cylinder; (c) pressure contour of hexagonal prism; (d) velocity contour of triangular prism; (e) velocity contour of square cylinder; (f) velocity contour of hexagonal prism.

在流体模拟计算过程中进行了同步的流场数据采集, 嵌入时程提取模块将计算中各时间步的

流场压力与速度值分类保存, 形成了各测点的压力时程与速度时程集参数. 具体测点布置如图 7 所示, 选取流向距离棱柱+2D—+8D 范围内、横向-3D—+3D 范围内, 展向一层范围内的流场测点, 单个算例中测点数为 3600 个, 包含了棱柱尾流的主要区域.




图 7 尾流监测点位置示意图

Fig. 7. Location of wake monitoring points.

为直观展示待训练样本的数据特征, 在压力样本集中随机选取了 6 条待训练的物理量时程进行展示, 如图 8 所示. 由于测点位置不同, 因而同一样本集内的时程信号特征各异; 又由于不同棱柱引起的尾流特征也不同, 因而不同样本集之间的时程信号特征也是不同的. 这种具有复杂特征的流场时程数据特征的提取与识别难以通过传统方法实现.

#### 4 模型训练与结果分析

根据上文的数值模拟结果, 以时程数据为研究对象, 建立输入时程与样本特征标签之间的深度学习模型, 并用训练数据集进行模型的有监督训练, 进而采用验证集验证模型的准确性.

##### 4.1 模型计算参数

根据 3 种棱柱的数值模拟计算, 分别得到了各算例中的 3600 个压力时程样本与 3600 个速度时程样本. 将相同物理量样本合并为速度样本集与压力样本集, 各包含了 10800 个具有 3 种不同特征的时程样本. 为减小各样本长度以减少深度学习模型的参数个数, 同时保证输入数据的采样间隔足以解析时程信号的波动特征, 本文训练数据的采样间隔为 0.1 s. 具体模型参数见表 1, 可以看出, 各模型中 MLP 的参数最多, TCNN 参数最少; 由于没有使用局部池化, 同样基于卷积计算的 FCNN 深度

学习模型参数要远多于 TCNN; 4 种模型中, 结构最复杂的 RCNN 网络参数也远多于 FCNN 网络, 依然少于 MLP 模型. 在训练过程中, 从测点集中随机选取 10% 的样本作为训练集, 剩余 90% 样本作为验证集, 计算的迭代次数均为 100 次.




图 8 典型测点的流场参数时程 (a) 三棱柱; (b) 方柱; (c) 六棱柱

Fig. 8. Time history of flow field parameters at typical measuring points: (a) Triangular prism; (b) square cylinder; (c) hexagonal prism.

表 1 一维卷积神经网络模型参数

Table 1. Structural parameters of capillary of different kind of fluid.

名称	特征提取运算	加速收敛方法	网络层数	模型参数个数
MLP	全连接层	Dropout	10	662501
TCNN	卷积层	局部池化	8	961
FCNN	卷积层	归一化层	13	264833
RCNN	卷积层	残差直连层	43	504129

## 4.2 识别结果与分析

经过迭代训练计算,得到了4种深度模型在训练过程中的计算残差曲线与识别精度曲线,如图9所示.对于压力时程数据集,在训练过程中基于卷积的神经网络收敛性较好,损失值下降较快并保持稳定,而基于全连接层的MLP模型的收敛较慢,模型误差明显大于其他3种模型.在速度时程样本的训练中观察到了同样的现象.同时,两组物理变量的模型训练过程中均可见RCNN的损失值最

小,说明对于训练数据集的样本来说,RCNN识别到的时程特征与真实的特征标签一致性最高.

训练集上的模型精度曲线如图10所示.可以看出,所有模型在训练集上的模型精度都随着迭代而升高,损失值越低的模型其精度越高,同样可以发现RCNN在不同物理量的测试中都获得了高的识别准确率,说明其可以准确提取到流场时程的关键特征,并进行识别.

将4种模型对于3种流场特征识别的准确度汇总于图11,同样验证了RCNN在流场特征识别

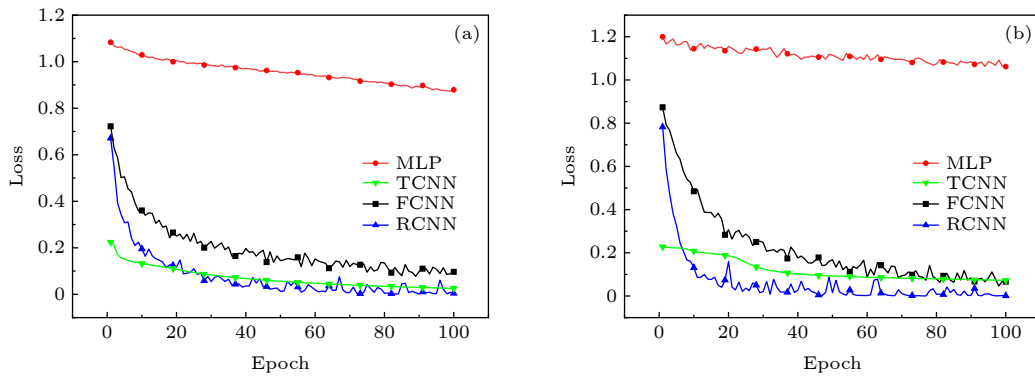


图9 训练集的模型损失值 (a) 压力; (b) 速度

Fig. 9. Loss function of different models on training set: (a) Pressure; (b) velocity.

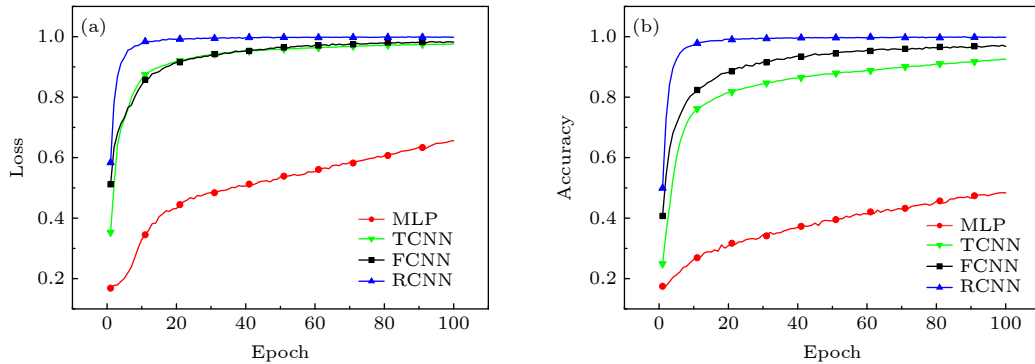


图10 训练集的模型精度 (a) 压力; (b) 速度

Fig. 10. Accuracy curve of different models on training set: (a) Pressure; (b) velocity.

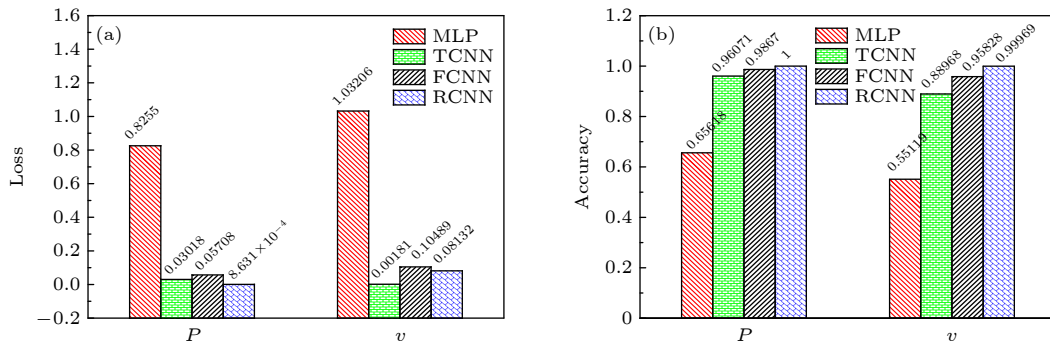


图11 验证集的最优模型结果 (a) 模型损失值; (b) 模型准确率

Fig. 11. Summary of best model on the validation set: (a) Model loss value; (b) model accuracy.



中的优势. 对于验证集, 图 11 同样证明了 RCNN 的高精度, 在压力和速度时程的特征识别方面, 最优模型达到了 99% 以上的准确率, 证明模型准确捕捉到了流场中的复杂抽象特征.

### 4.3 基于测点位置的识别精度可视化

为了直观展示流场不同区域的识别结果, 对 4 种模型训练得到最优模型的识别结果进行了可视化分析. 对神经网络在流场中各采样点的输出结果进行可视化, 若神经网络所得的流场特征标签与

实际标签不同, 在图中相应的测点位置处标注红色“×”号, 即神经网络的预测特征是错误的. 若识别结果正确, 则在相应的测点位置处用“o”表示. 进一步, 定义输出结果的“确信度”为输出单位向量中的最大值, 若最大值大于 0.9 用绿色表示, 0.8—0.9 之间用浅绿色表示, 0.7—0.8 之间用蓝色表示, 0.6—0.7 之间用浅蓝色表示, 0.5—0.6 之间用黄色表示. 压力时程与速度时程的识别结果分别如图 12 和图 13 所示.




图 12 压力时程的识别结果散点图 (a1)—(a4) 分别为 MLP, TCNN, FCNN, RCNN 第一类结果; (b1)—(b4) 分别为 MLP, TCNN, FCNN, RCNN 第二类结果; (c1)—(c4) 分别为 MLP, TCNN, FCNN, RCNN 第三类结果

Fig. 12. Identification results of pressure time history: (a1)—(a4) MLP, TCNN, FCNN, RCNN results of class1; (b1)—(b4) MLP, TCNN, FCNN, RCNN results of class2; (c1)—(c4) MLP, TCNN, FCNN, RCNN results of class3.






图 13 速度时程的识别结果散点图 (a1)–(a4) 分别为 MLP, TCNN, FCNN, RCNN 第一类结果; (b1)–(b4) 分别为 MLP, TCNN, FCNN, RCNN 第二类结果; (c1)–(c4) 分别为 MLP, TCNN, FCNN, RCNN 第三类结果

Fig. 13. Identification results of velocity time history: (a1)–(a4) MLP, TCNN, FCNN, RCNN results of class1; (b1)–(b4) MLP, TCNN, FCNN, RCNN results of class2; (c1)–(c4) MLP, TCNN, FCNN, RCNN results of class1.

从图 12 可以看出, MLP 模型的精度最低, 第一类与第二类棱柱的尾流区出现了大范围的错误结果, 同时第三类棱柱结果的确信度不高; TCNN 结果明显优于 MLP 结果, 但第二类棱柱尾部区域出现了部分的误判区域; FCNN 模型结果可靠性高, 而 RCNN 的最优模型得到了 100% 的正确结果, 同时确信度高, 说明 RCNN 准确地提取到了各流场的关键特征, 并实现了准确的特征识别。

图 13 所示为采用速度时程的进行模型训练及验证的结果. 与图 12 相比, 速度时程训练相同训

练步后, TCNN 的精度略低于压力时程信号, 对第二类棱柱的识别效果较差. 比较 4 种模型可以发现, 采用速度时程同样可以得到一致的结论, 即 MLP 模型的特征识别精度较差, RCNN 的结果最好。

## 5 结 论

本文采用深度学习方法对流场时程数据进行了特征提取研究, 构建了 4 种用于流场时程深度学习模型. 对具有三种具有不同特征的流场物理量时程集进行有监督训练, 每个数据集都包含了 10800

个时程数据, 其中 10% 的时程用来训练深度学习模型, 90% 的样本检验模型对特征识别的准确性. 结果表明: 1) 基于卷积的深度学习模型对流场识别精度高, 证明其对流场的特征提取准确; 2) 基于全连接方法的深度学习模型精度低, 难以准确提取流场时程的特征; 3) 所选深度学习的网络深度越深, 得到的模型识别精度更高; 4) 采用带有层间连接的残差卷积网络对流场特征的提取效果最好, 识别精度最高. 本文通过深度学习对流场时程数据进行分析, 证明了时程数据中包含丰富的流场特征信息, 是研究流场特征的新途径.

## 参考文献

- [1] Ye S R, Zhang Z, Wang Y W, Huang C G 2021 *Acta Aeronaut. Astronaut. Sin.* **42** 185 (in Chinese) [叶舒然, 张珍, 王一伟, 黄晨光 2021 航空学报 **42** 185]
- [2] Wang Y Q, Gui N 2019 *J. Hydrodyn.* **34** 413 (in Chinese) [王义乾, 桂南 2019 水动力学研究与进展 (A 辑) **34** 413]
- [3] Liu C Q 2020 *Acta Aerodyn. Sin.* **38** 413 (in Chinese) [刘超群 2020 空气动力学学报 **38** 413]
- [4] Wang Y X, Qian R K, Liu Z Y, Zhang Y, Chen G 2021 *Acta Aeronaut. Astronaut. Sin.* **42** 231 (in Chinese) [王怡星, 韩仁坤, 刘子扬, 张扬, 陈刚 2021 航空学报 **42** 231]
- [5] Ren F, Gao C Q, Tang H 2021 *Acta Aeronaut. Astronaut. Sin.* **42** 152 (in Chinese) [任峰, 高传强, 唐辉 2021 航空学报 **42** 152]
- [6] Wang N H, Lu P, Chang X H, Zhang L P 2021 *Chinese Journal of Theoretical and Applied Mechanics* **53** 740 (in Chinese) [王年华, 鲁鹏, 常兴华, 张来平 2021 力学学报 **53** 740]
- [7] Ling J, Kurzwski A, Templeton J 2016 *J. Fluid Mech.* **807** 155
- [8] Maulik R, San O, Jacob J D, Crick C 2019 *J. Fluid Mech.* **870** 784
- [9] Ren F, Wang C, Tang H 2019 *Phys. Fluids* **31** 093601
- [10] Ren F, Wang C, Tang H 2021 *Phys. Fluids* **33** 093602
- [11] Huang J, Liu H, Cai W 2019 *J. Fluid Mech.* **875** R2
- [12] Zhang Y, Azman A N, Xu K W, Kim H B 2020 *Exp. Fluids* **61** 1
- [13] Han J, Tao J, Wang C 2018 *IEEE Trans. Visual. Comput. Graphics* **26** 1732
- [14] Liu Y, Lu Y, Wang Y, Sun D, Deng L, Wang F, Lei Y 2019 *Comput. Fluids* **184** 1
- [15] Zhang Y, Azman A N, Xu K W, Kang C, Kim H B 2020 *Experiments in Fluids* **61** 1
- [16] Strfer C A M, Wu J, Xiao H, Paterson E 2018 *Commun. Comput. Phys.* **25** 625
- [17] Murata T, Fukami K, Fukagata K 2020 *J. Fluid Mech.* **882** A13
- [18] Omata N, Shirayama S 2019 *AIP Adv.* **9** 015006
- [19] Kai F, Nakamura T, Fukagata K 2020 *Phys. Fluids* **32** 095110
- [20] He K, Zhang X, Ren S, Sun J 2016 *European Conference on Computer Vision* Amsterdam, Netherlands, October 11–14, 2016 630
- [21] Szegedy C, Ioffe S, Vanhoucke V, Alemi A 2017 *Thirty-First AAAI Conference on Artificial Intelligence* San Francisco, California, USA, February 4–9, 2017
- [22] Liu F L, Li W H, Gong W G 2020 *CAD & CG* **32** 150 (in Chinese) [刘芙伶 李伟红 龚卫国 2020 计算机辅助设计与图形学报 **32** 150]
- [23] Zheng T Y, Wang S Y, Wang G X, Deng X G 2020 *Acta Phys. Sin.* **69** 204701 (in Chinese) [郑天韵, 王圣业, 王光学, 邓小刚 2020 物理学报 **69** 204701]
- [24] Srivastava N, Hinton G, Krizhevsky A, Sutskever I, Salakhutdinov R 2014 *J. Mach. Learn. Res.* **15** 1929
- [25] Krizhevsky A, Sutskever I, Hinton G E 2017 *Commun. ACM* **60** 84
- [26] Wang Z, Yan W, Oates T 2017 *International Joint Conference on Neural Networks (IJCNN)* Anchorage, Alaska, USA, May 14–19, 2017 p1578
- [27] Ioffe S 2017 *Proceedings of the 31st International Conference on Neural Information Processing Systems* Long Beach, California, USA, December 4–9, 2017 p1942
- [28] He K, Zhang X, Ren S, Sun J 2016 *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* Las Vegas, Nevada, USA, June 27–30, 2016 p770
- [29] Zhan Q L, Zhou Z Y, Ge Y J 2015 *J. Harbin Inst. Technol.* **47** 75 (in Chinese) [战庆亮, 周志勇, 葛耀君 2015 哈尔滨工业大学学报 **47** 75]

# Flow feature extraction models based on deep learning<sup>\*</sup>

Zhan Qing-Liang<sup>1)†</sup> Ge Yao-Jun<sup>2)</sup> Bai Chun-Jin<sup>1)</sup>

1) (*College of Transportation and Engineering, Dalian Maritime University, Dalian 116026, China*)

2) (*State Key Laboratory for Disaster Reduction in Civil Engineering, Tongji University, Shanghai 200092, China*)

( Received 25 July 2021; revised manuscript received 8 December 2021 )

## Abstract

Extraction and recognition of the features of flow field is an important research area of fluid mechanics. However, the wake flow field of object immersed in fluid is complicated in the case of medium- and high-Reynolds number, thus it is difficult to extract and recognize the key features by using traditional physical models and mathematical methods. The continuous development of deep learning theory provides us with a new method of recognizing the complex flow features. A new method of extracting the features of the flow time history is proposed based on deep learning in this work. The accuracy of four deep learning model for feature recognition is studied. The results show that the proposed model can identify different characteristics of the wake time history and object shapes accurately. Some conclusions can be obtained below (i) The model based on convolutional layers has higher accuracy and is suitable for analyzing the features of flow time history data. (ii) The residual convolutional network, with a deeper structure and more complex inter-layer structure, has highest accuracy for feature recognition. (iii) The proposed method can extract and recognize the flow features from the perspective of physical quantities time history, which is a high-accuracy method, and it is an important new way to study the features of flow physical quantities.

**Keywords:** flow feature extraction, deep learning, flow time history, residual convolution network, feature identification

**PACS:** 47.10.Fg, 47.11.-j, 47.85.-g

**DOI:** 10.7498/aps.71.20211373

---

<sup>\*</sup> Project supported by the the National Natural Science Foundation of China (Grant Nos. 51778495, 51978527), the Open Project of Key Laboratory of Bridge Structure Wind Resistance Technology (Shanghai), China (Grant No. KLWRTBMC21-02), and the Research Project of the Education Department of Liaoning Province, China (Grant No. LJKZ0052).

<sup>†</sup> Corresponding author. E-mail: [zhanqingliang@163.com](mailto:zhanqingliang@163.com)