

基于改进的无锚框目标检测算法的涡检测

宣扬^{1,2,3}, 吕宏强⁴, 安慰⁴, 刘学军^{1,3}

(1. 南京航空航天大学计算机科学与技术学院, 模式分析与机器智能工业和信息化部重点实验室, 南京 211106; 2. 中国空气动力研究与发展中心空气动力学国家重点实验室, 气动噪声控制重点实验室, 绵阳 621000; 3. 软件新技术与产业化协同创新中心, 南京 210023; 4. 南京航空航天大学航空学院, 南京 210016)

摘要: 在流体运动中涡对各种流场结构的生成和维持起着至关重要的作用, 涡的识别和检测有助于理解流体流动规律。传统涡识别方法别存在定义不准确、严重依赖经验阈值、泛化性能差等问题, 因此涡检测具有一定挑战性。本文从计算机视觉的角度出发, 提出了一个基于目标检测算法的涡检测模型。针对原始目标检测模型对极端宽高比的细长涡检测效果不理想的问题, 对两种不同类型涡的数据特性进行分析, 并提出了基于可变形卷积(Deformable convolutional network, DCN)的特征自适应模块和基于改进损失函数的细长样本挖掘方法。采用圆柱尾流涡和潜艇尾部涡数据集对所提模型进行验证, 实验结果表明改进后的模型检测精确率显著提高, 并在细长涡的检测精确率上有显著提升, 有效地平衡了各类型的涡检测性能。

关键词: 涡检测; 细长目标检测; 无锚框目标检测算法; 特征自适应; 细长样本挖掘

中图分类号: TP312 **文献标志码:** A

Vortex Detection Based on Improved Anchor-Free Object Detection Algorithm

XUAN Yang^{1,2,3}, LYU Hongqiang⁴, AN Wei⁴, LIU Xuejun^{1,3}

(1. MIIT Key Laboratory of Pattern Analysis and Machine Intelligence, College of Computer Science and Technology, Nanjing University of Aeronautics & Astronautics, Nanjing 211106, China; 2. Key Laboratory of Aerodynamic Noise Control, State Key Laboratory of Aerodynamics, China Aerodynamics Research and Development Center, Mianyang 621000, China; 3. Collaborative Innovation Center of Novel Software Technology and Industrialization, Nanjing 210023, China; 4. College of Aerospace Engineering, Nanjing University of Aeronautics & Astronautics, Nanjing 211106, China)

Abstract: Vortex plays a crucial role in the formation and maintenance of various flow structures in fluid motion. The identification and detection of vortices are helpful to understand the flow laws. Traditional vortex detection methods have many shortcomings, such as inaccurate definition, heavy dependence on empirical threshold and poor generalization performance, which make vortex detection challenging. In this paper, a vortex detection model based on object detection algorithm is proposed from the perspective of computer vision. Aiming at the problem that the original object detection model has unsatisfactory detection accuracy on slender vortices with extreme aspect ratio, this paper analyzes the data characteristics of two different types of vortices. A feature adaptive module based on deformable convolutional network (DCN)

基金项目: 航空科学基金(2018ZA52002, 2019ZA052011); 空气动力学国家重点实验室基金(SKLA20180102); 气动噪声控制重点实验室基金(ANCL20190103)。

收稿日期: 2022-01-04; **修订日期:** 2022-02-24

and a slender sample mining method based on improved loss function are proposed. The cylindrical wake vortex and submarine tail vortex data sets are used to verify the proposed model. Experimental results show that the improved model improves the detection accuracy significantly, and the detection accuracy of slender vortex is especially significantly improved, which effectively balances the performance of various types of vortex detection.

Key words: vortex detection; slender object detection; anchor-free object detection; feature adaptation; slender sample mining

引 言

涡在自然界中的形式多种多样,飓风、河流中的旋涡都属于涡。涡在流体的各种活动中频繁出现并对各种流场结构的生成和转换起着至关重要的作用。涡常见于湍流中,它们的形式多样、尺度不一,它们的出现使得流场运动变得紊乱。由于流体的黏性作用,混杂的涡运动使得流场中的能量快速损耗。涡的识别和检测能够帮助人们理解涡的运动规律,在飞行器和航行器外形设计时提供辅助信息。

涡的识别和检测是一项极具挑战的课题,其中一个主要原因是涡的确切定义非常困难,目前还没有一个被大家普遍接受的涡的定义^[1-2]。直观上,涡就是一团旋转的流体,是流体转动的结果,但是涡并没有一个严格的数学定义。第一代涡识别方法由 Helmholtz^[3]提出,文中把涡的强度定义为涡量大小。而之后的研究表明涡和涡量并不能完全等价^[4-5]。针对涡和涡量混淆的问题,第二代涡方法,如 λ 、 Q 、 Δ 方法^[6-9]整体考虑速度梯度张量,以特征值为基础进行涡识别,而不是简单地只考虑涡量。近年来,吴介之等^[10]结合流体运动肌腱的动力学机制提出,涡是有旋流体在各种运动学效应和大雷诺数动力学效应下,通过剪切层卷绕和涡量拉伸自组织成的管状结构。该定义与计算流体力学(Computational fluid dynamics, CFD)中的涡量面理论相契合,是涡研究的重要方向。

以上方法均为流体力学领域基于物理推导的传统方法,它们存在涡定义不准确、依赖经验阈值、泛化性能差等问题。随着机器学习的快速发展,特别是深度学习^[11-12]的迅速发展,越来越多的机器学习算法被应用于涡检测中。Zhang 等^[13]使用 Adaboost 算法为 4 种局域涡检测器赋值,并在 2 个 CFD 仿真数据集中获得了较低的错分率。Biswas 等^[14]引入了模糊理论,与 Adaboost 方法相比,模糊理论的涡检测方法为每个局域检测器分配相同的权重,将 4 种局域涡检测方法的输出不确定性结合起来,该方法具有更强的鲁棒性。已有的这些方法可以减少涡检测的假阳率和假阴率,提高识别的准确率,但由于集成了多种局域涡检测方法,也增加了计算成本,更重要的是这些方法都是与涡的大小和形状强相关的,可扩展性和泛化性不足。

卷积神经网络(Convolutional neural network, CNN)也被广泛地应用于涡检测中。Ströfer 等^[15]将 CNN 应用于三维流场中的马蹄涡检测,模型只适用于单连通的均匀网格,模型输入为流场中每个点的伽利略不变量,伽利略不变量的计算复杂度高。Franz 等^[16]提出了基于 CNN 的海洋涡检测算法,训练数据的标记为精度较低的局域流场信息。Deng 等^[17]利用 CNN,把涡检测当做二分类任务,模型的输入为分割后的局域流场数据,利用高精度的全局流场信息做数据标记,输出为局域流场的类别(涡和非涡),需要对每一块局域流场信息单独地进行卷积运算,预测精确度依赖于对流场划分的粒度。上述方法存在计算复杂度高、检测精确率低及泛化性能低等不足。

近年来,基于深度学习的目标检测算法取得了显著的成果,并被广泛地应用于各个领域,如行人检测、车辆检测和缺陷检测等。目标检测的任务是从图像数据中识别并定位感兴趣目标的位置,包括图像分类和位置回归两个学习任务。基于深度学习的目标检测模型的输入为图像数据,输出为边界框形

式的目标对象,利用标记真实标签的训练数据对模型进行训练。基于深度学习的目标检测算法可以分为基于锚框和无锚框的检测算法,基于锚框的算法可以进一步分为单阶段和两阶段的检测算法。单阶段的算法包括YOLO系列算法^[18]、SSD算法^[19]和Retina-Net^[20]等,它们的特点是检测速度快但预测精确率和召回率较低。两阶段的算法包括Faster-RCNN^[21]、Cascade-RCNN^[22]等,它们的特点是精确率和召回率高但是检测速度较慢。经典的无锚框算法包括Corner-Net^[23]、FCOS^[24]等,它们在建模时把预测目标从相对于预定义锚框的偏移量改为直接预测点对(物体的左上角和右下角的点)或者相对于物体中心点的偏移向量(中心点距离边界框四条边的距离),减轻了对预定义锚框的依赖,并减少了模型计算量。

涡检测的目标是从流场数据中识别并定位出涡,这与目标检测的任务一致,因此本文提出使用无锚框目标检测算法FCOS模型进行涡检测,模型的输入为流场的速度云图,以边界框的形式给出涡所在区域,并针对原始目标检测模型在极端宽高比的细长涡上取得的精确率较低的问题,提出了基于可变形卷积的特征自适应模块和基于改进损失函数的细长样本挖掘方法。特征自适应模块可以获得感受野可变的特征图,而细长样本挖掘可以使模型更加关注细长涡样本,改进后的模型检测精确率显著提升。本文所提方法有如下优势:从视觉的角度出发对数据进行标记,符合涡的直观定义,不存在定义不准确的问题;只需标记好的涡数据集就可以对模型进行端到端的训练,而不需要其他经验阈值;能够检测出不同场景下不同类型的涡,有较好的泛化能力;提高了细长涡的检测精确率,不同类型涡的检测性能平衡。通过模拟计算生成的圆柱绕流和吕氏一号线型潜艇周围流场的数据集验证了本文所提方法的有效性。

1 实验方法

1.1 涡检测问题分析

不同于普通的目标检测对象,涡的种类多种多样,形式复杂多变。不同种类的涡,在数据上表现出不同的性质。这些性质差异影响着检测模型的泛化性能,有必要对不同涡的分布和性质进行详细分析。

本文提出的基于深度学习的涡检测框架如图1所示,该框架包括模型训练阶段和测试阶段。在训练阶段,利用人工标记好的流场云图,通过反向传播算法对涡检测模型进行训练。在测试阶段,将新的流场云图送入涡检测模型中进行预测,输出边界框形式涡检测结果。为了增强模型的泛化性能,实验数据集中包含了两类涡,即圆柱尾流涡和潜艇尾部涡,以覆盖多种形态的涡,其形态如图2所示,图中 U 代表速度分量,第1行为圆柱尾流的流场速度云图,第2行为潜艇周围的流场速度云图,实线方框代表涡的区域。图中第2列和第3列中的黑色线条代表流体运动的流线,这些流线在实际输入模型的时候并不存在,流线只用于数据的标注。观察图2可以发现,潜艇尾部的涡的宽高比更加极端,这些涡沿着边界框对角线贴附在潜艇表面。为了更好地分析问题,本文定义了细长度这一概念以描述涡的形态,定义细长度 e 为

$$e = \frac{\min(w, h)}{\max(w, h)} \in (0, 1] \quad (1)$$

式中 w 、 h 分别代表边界框的宽和高。在目标检测领域,常用边界框来表示检测的目标区域。 e 越小,物体的宽高比越极端,物体越细长。准确来说,这样定义的细长度是不够严谨的,如图3(a)所示,对于旋转的物体,即使是 $e=1$,它可能是细长的,也可能是非细长的。但是对于潜艇尾部涡这一场景,这样的定义是可以接受的,因为潜艇尾部的涡总是以较小的角度沿着边界框对角线贴附在潜艇表面,而不是 45° 这样极端的情况,如图3(b)所示。这样粗略的定义好处是可以减少数据标注的难度。条件允许的情

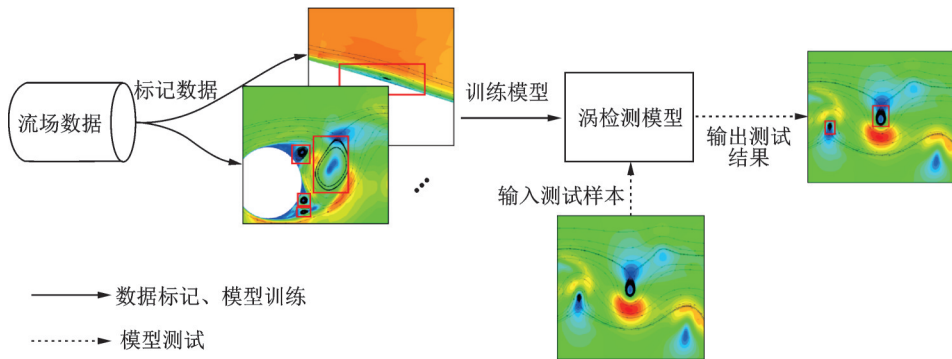


图1 基于深度学习的涡检测框架

Fig.1 Framework of vortex detection based on deep learning

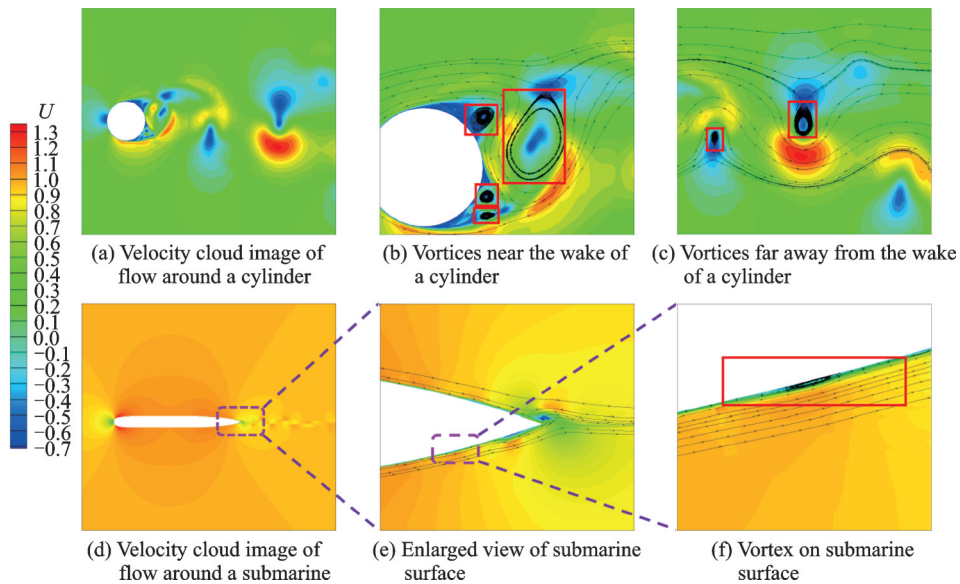


图2 两种涡的形式

Fig.2 Two kinds of vortices

况下,以带旋转角度的方框来标注数据要更为精确,如图3(a)中的虚线框所示。

数据集中两种类型涡的数量随细长度 e 的分布如图4所示,可以发现圆柱体尾部的涡和潜艇尾部的涡在细长度上明显是两种不同的模式。潜艇尾部的涡更加细长, e 的范围大致为 $[0.15, 0.4]$, 圆柱尾部的涡细长度 e 分布更广, 范围大致为 $[0.35, 1]$ 。潜艇尾部涡和圆柱体尾部涡的样本数量比大致为 $3:10$ 。

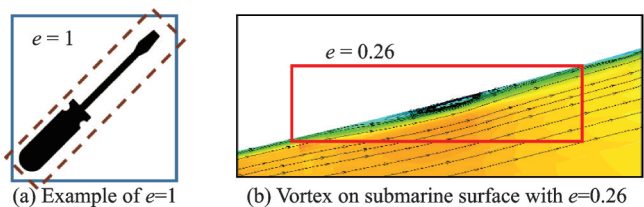


图3 细长目标的例子

Fig.3 Examples of elongated objects

本文在 Faster R-CNN 和 Retina-Net 这两个经典的检测器上进行了初步实验。模型的主干网络都基于特征金字塔网络 (Feature pyramid network, FPN)^[25] 和 ResNet-50^[26]。实验发现,模型在潜艇尾部涡上的精确率要明显小于圆柱尾涡的精确率,可以认为潜艇尾部细长涡的检测难度要显著大于圆柱

尾流涡的检测难度,这其中有两方面的原因:(1)潜艇尾部涡的数据样本较少;(2)潜艇尾部涡的宽高比更极端,更难进行特征提取。显然想要提高模型的整体性能,使得其有较好的泛化性能,提高模型在潜艇尾部涡上的检测性能是关键。

针对潜艇尾部涡识别问题可以推广为拥有极端宽高比的细长目标识别问题。针对特定问题的目标识别,例如小目标识别问题^[27]和稠密目标识别问题^[28-29]已经有了相关的研究,但对于细长目标识别的研究还较少。为提升潜艇尾部涡检测精确率,本文从特征提取和损失函数的角度出发,在FCOS模型的基础上提出了基于可变形卷积的特征自适应模块和基于改进损失函数的细长样本挖掘方法。

1.2 FCOS检测模型

经典的检测算法如Faster R-CNN、RetinaNet等都依赖于预定义的先验锚框,锚框一直被当做目标检测必要组件,检测模型的输出为锚框所属的类别和相对于先验锚框的偏移量。基于锚框的目标检测算法取得了巨大的成功,但也存在一些缺陷,例如:(1)模型性能对预先定义的锚框的尺寸、宽高比和数量参数敏感;(2)对于极端尺寸的目标检测效果差,如细长目标检测、小目标检测;(3)需要稠密的锚框来保证模型的召回率,大量的锚框会导致过高的计算量和过多负样本。基于无锚框的目标检测算法的提出,缓解了上述的问题,并且无锚框检测算法也能取得高检测性能。

FCOS是一种基于全卷积的无锚框的目标检测算法,它的整体网络结构如图5所示,图中C3~C5表示主干网络特征图,P3~P7表示最终预测特征级别,W、H、K分别表示特征图宽度、高度和分类类别数。FCOS可以分为3个部分:ResNet主干网络用于特征提取;特征金字塔网络FPN用于获得不同尺度的特征图;预测头网络Head用于实际预测输出。其中,预测头网络有3个分支:类别预测分支、Center-ness预测分支和边框回归分支。图5中的自适应模块是本文提出的用于加强特征提取形变能力的新结构。

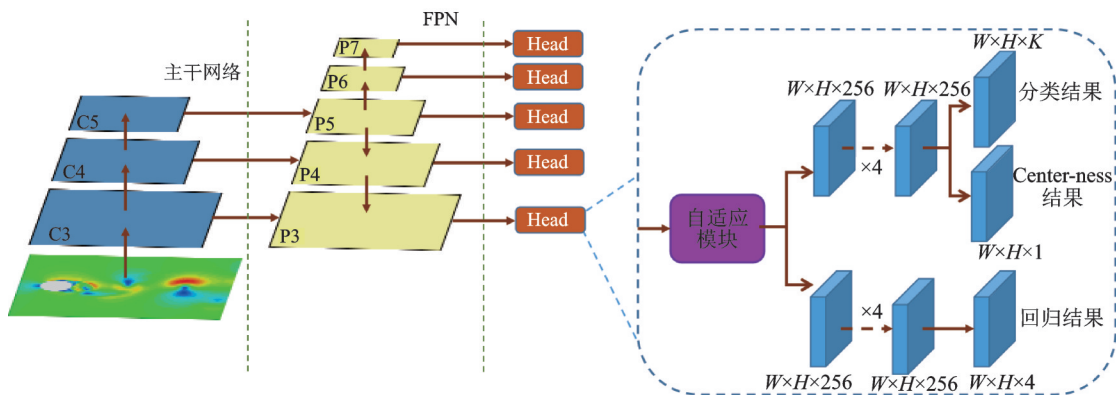


图5 FCOS的网络结构

Fig.5 Network structure of FCOS

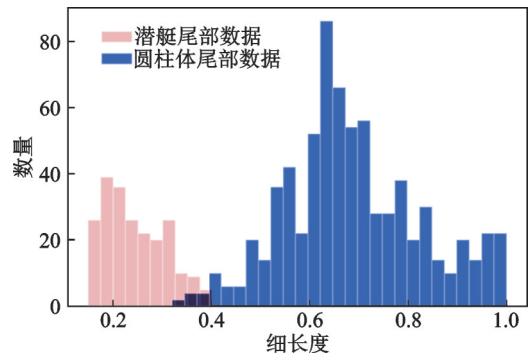


图4 数据集的细长度分布

Fig.4 Distribution of slenderness of data set

基于锚框的目标检测算法的回归分支预测值是相对于先验锚框的偏移量,而FCOS的回归分支直接预测特征图上每个位置可能存在的目标边框。具体来说,回归子网络为特征图上的每个带点预测一个四维向量 (l, r, t, b) 代表该点到目标4个边框的距离,如图6所示。分类子网络为特征图上的每个点预测一个 K 维向量,代表该点为 K 个类别的概率。

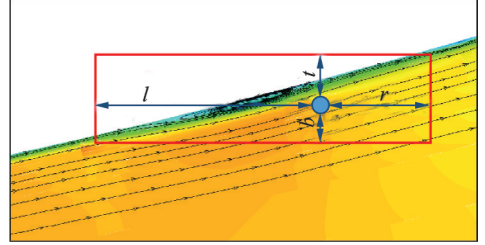


图6 FCOS预测的四维向量 (l, r, t, b)
Fig.6 Predicted 4D vector (l, r, t, b) of FCOS

训练过程中,当输入图像上的一点 (x, y) 落入到真实标签边框内时,该点在特征图上对应位置被当做正样本,对于一个点同时落入多个真实标签边框内的情况(多个边框相交的区域),为了避免歧义,FCOS将不同尺寸的边框分配至FPN多个特征层中,当相交边框存于同一特征层中时,选择面积最小的边框作为该点的真实标签。模型的损失函数如下

$$L(\{p_{x,y}\}, \{t_{x,y}\}) = \frac{1}{N_{\text{pos}}}_{x,y} \sum L_{\text{cls}}(p_i, p_i^*) + \lambda \frac{1}{N_{\text{pos}}}_{x,y} \sum c_{x,y}^* L_{\text{reg}}(t_{x,y}, t_{x,y}^*) \quad (2)$$

式中: $p_{x,y}$ 和 $t_{x,y}$ 代表点 (x, y) 处预测的类别向量和边框回归向量; L_{cls} 为分类损失; p_i 和 p_i^* 分别代表 (x, y) 处预测的类别向量和真实类别;当标签为前景时, $c_{x,y}^* > 0$,为背景时, $c_{x,y}^* = 0$; L_{reg} 为回归损失; $t_{x,y}$ 和 $t_{x,y}^*$ 分别代表 (x, y) 处预测的预测边框和真实边框; N_{pos} 代表预测正样本的个数; λ 代表分类损失与回归损失的平衡因子。

Center-ness是FCOS检测算法特有的输出量。因为FCOS把真实标签边界框内的所有点都当做正样本,所以在边界框附近存在很多低质量的预测边界框,Center-ness用于抑制低质量预测边界框,它的计算公式如下

$$\text{Centerness} = \left(\frac{\min(l, r)}{\max(l, r)} \times \frac{\min(t, b)}{\max(t, b)} \right)^{\frac{1}{2}} \quad (3)$$

式中 (l, r, t, b) 代表预测点到目标4个边框的距离。

Center-ness的取值范围是 $(0, 1]$,通过二值交叉熵(Binary cross entropy, BCE)损失加入到分类损失和回归损失中一起训练。在测试阶段,将Center-ness和分类损失的乘积作为预测的置信度,再通过非极大抑制算法(Non maximum suppression, NMS)进行处理得到最终的预测结果。Center-ness分支可以有效地提高模型检测的性能。

1.3 特征自适应模块

检测算法对于细长目标的检测精确率低的一个原因是,细长目标的真实标签区域包含了更多与目标本身无关的背景信息,如图6所示红色边框内的白色区域和黄色区域的大部分都是背景信息,过多的背景信息会对检测器的性能造成影响。标准卷积的卷积核是规则的方形卷积核,卷积核在卷积运算时,规则地在输入图像上依次滑动采样,卷积核的感受野是固定的,这就导致细长物体的特征图中必然包含过多不相关的背景信息,而可变形卷积网络(Deformable convolution net, DCN)^[30]通过在原始采样点上增加一个偏移量,从而使卷积运算能够根据输入数据自适应地调整采样位置和感受野的范围,可以在不固定感受野上提取信息,拥有更强的特征提取自适应能力。

传统卷积与可变形卷积的对比如图7所示,图中红色的点代表标准卷积的采样点,紫色的点代表可变形卷积的采样点,箭头代表可变形卷积采样点相对于标准卷积采样点的偏移量。对于输出特征图 y 上的一点 p_0 ,传统卷积的公式可以表示为

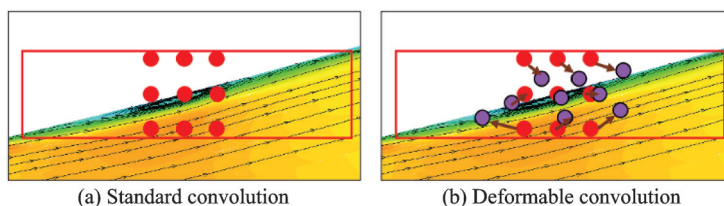


图7 标准卷积与可变形卷积的对比

Fig.7 Contrast between standard convolution and deformable convolution

$$y(\mathbf{p}_0) = \sum_{\mathbf{p}_n \in R} v(\mathbf{p}_n) \cdot x(\mathbf{p}_n + \mathbf{p}_0) \quad (4)$$

式中: x 代表输入的特征图; R 代表 \mathbf{p}_0 周围的采样区域; \mathbf{p}_n 代表 R 中的采样点; v 代表卷积核的权重。可变形卷积的采样点在标准卷积的采样点的基础上增加了偏移量,偏移量是通过额外的标准卷积分支计算的来的,如图8所示。添加了偏移量的可变形卷积的公式如下

$$y(\mathbf{p}_0) = \sum_{\mathbf{p}_n \in R} v(\mathbf{p}_n) \cdot x(\mathbf{p}_n + \mathbf{p}_0 + \Delta\mathbf{p}_n) \quad (5)$$

式中: $\Delta\mathbf{p}_n$ 代表由额外卷积分支得到的二维偏移量(水平和垂直两个维度的偏移量)。 $\Delta\mathbf{p}_n$ 偏移量使得卷积采样的位置从固定的变成了可以自适应调整的,从而使卷积运算能够根据输入数据自适应地调整感受野的位置和范围,拥有更强的特征提取能力。可变形卷积可以直接由反向传播算法优化得到。

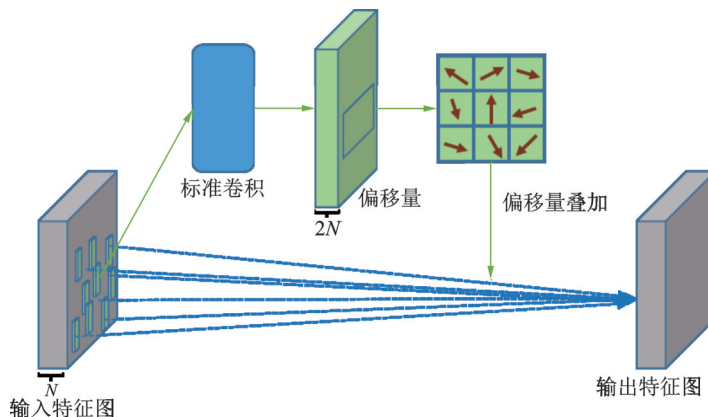


图8 可变形卷积

Fig.8 Deformable convolution

本文提出的特征自适应模块由单层可变形卷积构成,它并不需要额外的监督信息,仅受到损失函数的监督。增加了特征自适应模块的FCOS网络结构如图5所示,特征自适应模块设置在检测头的开始位置,由它统一进行特征提取后的特征图被送入到后续的分类分支、边框回归分支和Center-ness分支,这样设计的目的是为了在尽量少增加参数数量的前提下,所有预测分支都能受益于特征自适应模块提取的特征,实现特征共享。可变形卷积能够很好地用于本文细长涡检测的场景,并且只增加了非常少的参数数量,并不会显著增加模型的训练难度和训练时间。

1.4 细长样本挖掘

直接增加细长样本在训练集中的比例可以简单有效地提高细长样本的检测精确率,但也会导致模型整体检测精确率和召回率的下降。这是由于在无法扩充数据集的情况下,提高潜艇尾部涡的比例是通

过降低圆柱尾流涡样本数量的方法完成的。

对损失函数进行改进是解决样本不均衡问题的一个常见思路。在目标检测领域,Focal Loss^[20]是常用的解决难、易样本不平衡问题的损失函数。Focal Loss 区别对待难、易样本和正、负样本,使模型更加关注困难的正样本,以降低模型的训练难度。本文中FCOS模型和RetinaNet模型的类别预测分支都使用了Focal Loss作为损失函数。

受到Focal Loss的启发,本文对FCOS的Center-ness预测分支的损失函数进行了改进,将其指数从固定的0.5变为涡的细长度,以让模型训练优化时更多关注细长的涡,对式(3)的改进如下

$$\text{Centerness}^* = \left(\frac{\min(l, r)}{\max(l, r)} \times \frac{\min(t, b)}{\max(t, b)} \right)^e \quad (6)$$

式中: $e \in (0, 1]$ 代表涡的细长度,细长度由式(1)计算得到, e 越小,物体的宽高比越极端,物体越细长。式(6)底数取值范围是 $(0, 1]$ 。改进后,细长涡的Center-ness损失占比变大,使得模型更加关注细长的涡。相比于改变训练数据集的采样比例的方法,改进的Center-ness不需要人为干预就可以自动地根据数据集本身特点进行自适应地调整,且无需增加额外的计算量。

2 实验与分析

2.1 实验数据

本文利用LES(Large eddy simulation)生成圆柱绕流和吕氏一号线型潜艇周围流场的模拟数据进行实验,流场的雷诺数分别为20 000和3 750 000。LES是一种湍流数值模拟方法,能够在可接受的计算时间复杂度内,生成精确的流场数据。由于整个流场的分辨率非常大,为了降低计算复杂度,需要将流场数据裁剪成合适的大小,裁剪后本文数据集中的流场速度云图大小为1 024像素×1 024像素。

数据集标注时,以流体力学软件生成的流线作为判断依据,闭合流线所包围的区域即为涡,如图2所示,图中红色边界框内的区域即为涡。数据集中包含两种涡,圆柱尾流涡和潜艇尾部涡,圆柱尾流涡的样本数为726例,潜艇尾部涡样本数为219例,它们的形式如图2所示,将它们分别随机采样20%作为测试集,其余作为训练集。

2.2 评价指标

目标检测任务中常用平均精确率(Average precision, AP)和平均召回率(Average recall, AR)对模型性能进行评估,其中AP值更受人们关注,简单来说,AP就是在PR(Precision-recall)曲线上对精确率求平均,也即PR曲线所围面积。不同IoU(Intersection over union)阈值下,可以计算出不同的AP值,mAP是指IoU阈值从0.5到0.95区间上每间隔0.05计算一次的所有类别AP值的直接平均,表示模型在多个类别上的综合性能。AP₅₀、AP₇₅分别代表IoU阈值为0.5和0.75时所有类别的AP值的平均。相比AP₅₀,AP₇₅对预测边框的质量要求更高。

特别地,本文AP_c、AP_s分别指检测模型在圆柱尾流涡和潜艇尾部涡上单独一类的不同IoU阈值下的AP平均值;mAP值为两类涡单独检测精度的平均值,即AP_c和AP_s的平均值。

2.3 不同检测算法的对比

基于锚框算法的性能对预先定义的锚框的尺寸、宽高比和数量参数比较敏感,且对于极端尺寸的目标检测效果并不理想,而无锚框的检测算法并不依赖于预定义的锚框。本文选取了经典的两阶段检测算法Faster R-CNN、单阶段检测算法Retina-Net和无锚框的FCOS进行对比。3种算法都采用了ResNet-50作为主干特征提取网络,并利用特征金字塔FPN进行多尺度预测,所有超参数都采用默认的设置。

三者的对比实验结果如表1所示,可以发现,3个模型在潜艇尾部涡上的精确率要明显小于圆柱尾流涡的精确率,可认为潜艇尾部细长涡的检测难度要显著大于圆柱尾流涡的检测难度。除此之外,还发现FCOS相比Retina-Net只有略微的优势,具体来说,FCOS在潜艇尾部涡精确率 AP_s 提升了0.8%,两类平均精确率mAP提升了0.3%,而在圆柱尾流涡上精确率 AP_c 和平均召回率AR略微下降了。进一步可以发现,相较于Retina-Net,FCOS在 AP_{75} 指标上提升了1.1%,而在 AP_{50} 指标上下降了1.1%,说明FCOS能够提供更多高质量的预测边界框,可能的原因是FCOS特有的Center-ness分支抑制了低质量的预测边界框。因此,针对涡检测,FCOS相对于基于锚框的Faster R-CNN和Retina-Net在细长涡检测上有优势但不显著,还需要其他手段来提升FCOS的检测性能。

表1 不同类型检测模型在涡检测上的表现

Table 1 Performance of different detection models in vortex detection

模型	AP_c	AP_s	mAP	AP_{50}	AP_{75}	AR
Faster R-CNN	50.7	40.9	45.8	78.2	39.8	59.0
Retina-Net	51.2	41.4	46.3	78.7	40.1	61.0
FCOS	51.0	42.2	46.6	77.6	41.2	60.8

2.4 改变采样比例对模型性能的影响

一个直观的缓解细长目标识别的方法是提高训练数据集中细长物体的采样比例,在不增加新样本的情况下,只能变相地降低圆柱尾流涡的比例。本文在Faster R-CNN上,使用不同采样比例的数据集对模型进行训练,实验发现,适当提高细长涡的采样比例可以使潜艇尾部涡的检测性能提高,但降低了总体性能,如表2所示,这是因为圆柱尾流涡训练样本数量的减少造成的,因此改变采样比例并不是一种最优的策略。本文希望在提升潜艇尾部涡检测精确率的同时,保持圆柱尾流涡的检测性能不下降。

表2 采样比例对模型性能的影响

Table 2 Influence of sampling ratio on model performance

采样比例 (潜艇:圆柱)	AP_c	AP_s	mAP	AR
3:10	50.7	40.9	45.8	59.0
3:5	45.9	42.1	44.0	56.6
1:1	40.3	41.6	41.0	50.4

2.5 自适应模块的对比实验

为了验证自适应模块的特征自提取提取能力,本文在ResNet-50和ResNe-101两种大小的主干网络上对FCOS进行了对比实验,实验结果如表3所示。可以发现,在大小相同的主干网络上,自适应模块的加入提高了模型的平均精确率和召回率,并且对于细长的潜艇尾部涡精确率的提升比圆柱尾流涡精确率的提升更多,这说明特征自适应模块对于细长样本的特征质量提升更显著。一般来说小的网络模型提取的特征质量较差,而大的网络模型提取的特征质量较高,可以发现对于更小的主干网络ResNet-50,自适应模块提升的精确率要更多,这说明自适应模块对于低质量特征的自适应能力要更好。实验结果验证了自适应模块在FCOS上对于特征提取的有效性。

2.6 改进Center-ness的对比实验

为了缓解样本不平衡造成的问题,本文提出了改进的Center-ness以使模型更加关注涡检测中的细长样本。表4给出了改进的Center-ness在ResNet-50上的验证实验,Center-ness*代表改进的Center-ness。从实验结果中可以发现,单独加入Center-ness*可以在略微降低圆柱尾流涡的检测精确度的情况下,使细长的潜艇尾部涡的检测精确率提高3.5%,并使模型的检测平均精确度提升0.9%。相对

表 3 自适应模块在 FCOS 上的验证实验

Table 3 Validation experiment of adaptive module on FCOS

主干网络	自适应	AP _c	AP _s	mAP	AP ₅₀	AP ₇₅	AR
ResNet-50	×	51.0	42.2	46.6	77.6	41.2	60.8
ResNet-50	√	51.8	44.6	48.2	79.6	42.3	61.7
ResNet-101	×	52.7	44.0	48.4	80.0	42.3	62.3
ResNet-101	√	53.3	45.7	49.5	77.8	42.9	62.8

表 4 改进 Center-ness 在 ResNet-50 上的验证实验

Table 4 Improved Center-ness validation experiments on ResNet-50

Center-ness*	自适应	AP _c	AP _s	mAP	AP50	AP75	AR
		51.0	42.2	46.6	77.6	41.2	60.8
	√	51.8	44.6	48.2	79.6	42.3	61.7
√		49.3	45.7	47.5	78.9	41.1	62.9
√	√	51.1	47.5	49.3	80.9	42.8	62.6

于只加入自适应模块的模型来说,同时加入自适应模块和 Center-ness*模型在平均检测精确率上进一步提升 1.1%,在潜艇尾部涡的检测精确率上提高 2.9%,但在圆柱尾流涡检测精确率下降 0.7%。这相当于在尽量不降低圆柱尾流涡检测精确率的同时提高了模型的平均检测性能,并显著提高了细长的潜艇尾部涡的检测精确率。与原始 FCOS 比较,加入自适应模块和 Center-ness*使得模型的平均精确率提升了 2.7%,潜艇尾部涡的精确率提升了 5.3%,平均召回率提升了 1.8%。上述实验结果表明 Center-ness*能够提升模型在潜艇尾部涡上的检测精确率,配合特征自适应模块能在不降低圆柱尾流涡检测精确度的条件下,提升模型的平均检测性能,并显著提升潜艇尾部涡检测的检测精确率。结合 Center-ness*和特征自适应模块的 FCOS 模型的部分测试结果如图 9 所示,图中红框代表真实标签,黑

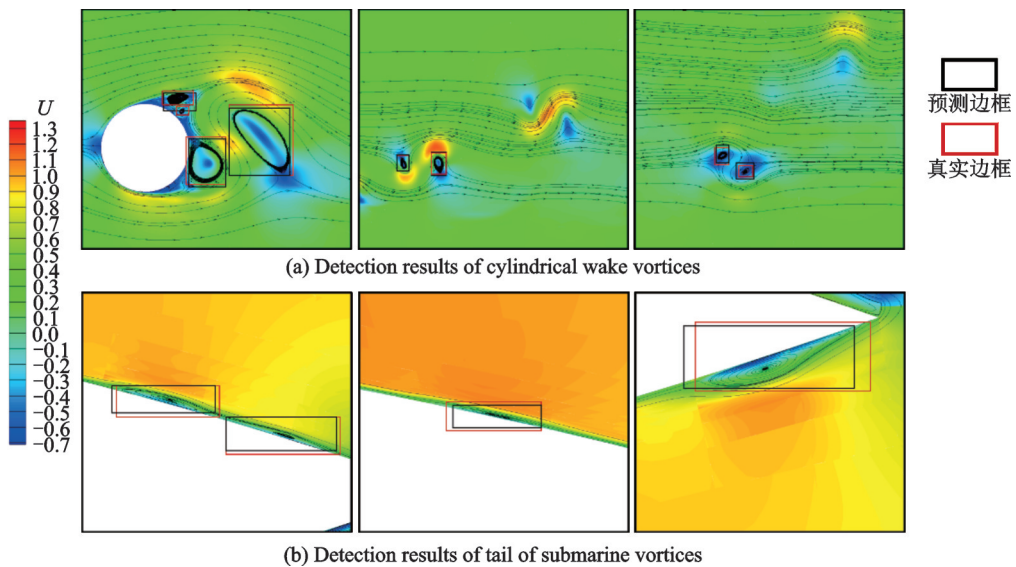


图 9 改进模型的部分预测结果

Fig.9 Some prediction results of the improved model

框代表预测边框。在图9第1行左边第1张流场云图中,漏检了贴近圆柱物面的一个涡,这是由于LES数据在贴近圆柱物面处的精度较低,云图的质量较差,导致模型很难有效地提取该处的流场特征。除此之外,模型能够准确地检测出流场中的涡,提供高质量的预测边框。

3 结束语

针对传统涡检测的缺陷,本文从视觉角度出发提出基于深度学习的涡检测模型,涡的定义明确,不依赖于经验阈值,且能够识别不同类型的涡,泛化性能强。针对细长涡检测精确率低的问题,提出了3点改进:首先采用无锚框的FCOS检测模型,配合特征金字塔FPN进行涡检测;其次,提出了基于可变形卷积的特征自适应模块,使得卷积能够在可变的感受野上进行自适应的特征提取,忽略与涡无关的背景信息;最后,针对涡检测中样本不平衡问题,提出了基于改进损失函数的细长样本挖掘的方法,使得模型更加关注细长涡样本。结合以上改进,本文的涡检测模型能够精确且快速地检测出二维流场中的两种涡,显著提高涡检测的精确率,特别是细长涡的检测精确率,做到两类涡之间的检测性能平衡。在未来的研究工作中,首先考虑对算法进行改进,将其推广到更具实用价值的三维流场;其次将扩展更多不同类型涡的样本和不同类型的流场结构,如流场中的边界层、马蹄形涡、Kelvin-Helmholtz涡、湍流相干结构、翼型表面的激波等,使得模型能够适用于更多场景,具有更好的泛化性能。

参考文献:

- [1] GREEN S I. Fluid vortices[J]. *International Journal of Multiphase Flow*, 1996, 22(Suppl 1): 91.
- [2] LIU C, YAN Y, LU P. Physics of turbulence generation and sustenance in a boundary layer[J]. *Computers & Fluids*, 2014, 102: 353-384.
- [3] HELMHOLTZ H. Über integrale der hydrodynamischen gleichungen, welche den wirbelbewegungen entsprechen [J]. *Journal Für Die Reine Und Angewandte Mathematik*, 2009, 1858(55): 25-55.
- [4] ROBINSON S K. Coherent motions in the turbulent boundary layer[J]. *Annual Review of Fluid Mechanics*, 1991, 23(1): 601-639.
- [5] WANG Y, YANG Y, YANG G, et al. DNS study on vortex and vorticity in late boundary layer transition[J]. *Communications in Computational Physics*, 2017, 22(2): 441-459.
- [6] JCR H, WRAY A, MOIN P. Eddies, stream, and convergence zones in turbulent flows[C]// *Proceedings of the 1988 Summer Program. USA: [s.n.], 1988: 193-208.*
- [7] JEONG J, HUSSAIN F. On the identification of a vortex[J]. *Journal of Fluid Mechanics*, 1995, 285: 69-94.
- [8] CHONG M S, PERRY A E, CANTWELL B J. A general classification of three-dimensional flow fields[J]. *Physics of Fluids A: Fluid Dynamics*, 1990, 2(5): 765-777.
- [9] ZHOU J, ADRIAN R J, BALACHANDAR S, et al. Mechanisms for generating coherent packets of hairpin vortices in channel flow[J]. *Journal of Fluid Mechanics*, 1999, 387: 353-396.
- [10] 吴介之, 杨越. 关于旋涡定义的思考[J]. *空气动力学学报*, 2020, 38(1): 1-8.
WU Jiezhi, YANG Yue. Thoughts on vortex definition[J]. *Acta Aerodynamica Sinica*, 2020, 38(1): 1-8.
- [11] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444.
- [12] BENGIO Y. Learning deep architectures for AI[J]. *Foundations and Trends in Machine Learning*, 2009, 2(1): 1-127.
- [13] ZHANG L, DENG Q, MACHIRAJU R, et al. Boosting techniques for physics-based vortex detection[J]. *Computer Graphics Forum*, 2014, 33(1): 282-293.
- [14] BISWAS A, THOMPSON D, HE W, et al. An uncertainty-driven approach to vortex analysis using oracle consensus and spatial proximity[C]// *Proceedings of 2015 IEEE Pacific Visualization Symposium (PacificVis). USA: IEEE, 2015: 223-230.*
- [15] STRÖFER C M, WU J, XIAO H, et al. Data-driven, physics-based feature extraction from fluid flow fields[EB/OL]. (2018-02-02)[2021-11-30]. <http://export.arxiv.org/abs/1802.00775>.
- [16] FRANZ K, ROSCHER R, MILIOTO A, et al. Ocean eddy identification and tracking using neural networks[C]//

- Proceedings of IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium. USA: IEEE, 2018: 6887-6890.
- [17] DENG L, WANG Y, LIU Y, et al. A CNN-based vortex identification method[J]. Journal of Visualization, 2019, 22(1): 65-78.
- [18] REDMON J, FARHADI A. Yolov3: An incremental improvements[EB/OL]. (2018-04-08)[2021-11-30]. <https://arxiv.org/abs/1804.02767>.
- [19] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]// Proceedings of European Conference on Computer Vision. Cham: Springer, 2016: 21-37.
- [20] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]//Proceedings of the IEEE International Conference on Computer Vision. USA: IEEE, 2017: 2980-2988.
- [21] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. Advances in Neural Information Processing Systems, 2015, 28: 91-99.
- [22] CAI Z, VASCONCELOS N. Cascade R-CNN: Delving into high quality object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2018: 6154-6162.
- [23] LAW H, DENG J. Cornernet: Detecting objects as paired keypoints[C]//Proceedings of the European Conference on Computer Vision (ECCV). [S.l.]: Springer, 2018: 734-750.
- [24] TIAN Z, SHEN C, CHEN H, et al. FCOS: Fully convolutional one-stage object detection[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. USA: IEEE, 2019: 9627-9636.
- [25] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2017: 2117-2125.
- [26] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. USA: IEEE, 2016: 770-778.
- [27] ZOPH B, CUBUK E D, GHIASI G, et al. Learning data augmentation strategies for object detection[C]// Proceedings of European Conference on Computer Vision. Cham: Springer, 2020: 566-583.
- [28] FLORENCE P R, MANUELLI L, TEDRAKE R. Dense object nets: Learning dense visual object descriptors by and for robotic manipulation[EB/OL]. (2018-09-07)[2021-11-30]. <https://arxiv.org/abs/1806.08756>.
- [29] HUANG L, YANG Y, DENG Y, et al. Densebox: Unifying landmark localization with end to end object detection[EB/OL]. (2015-09-19)[2021-11-30]. <http://export.arxiv.org/abs/1509.04874>.
- [30] DAI J, QI H, XIONG Y, et al. Deformable convolutional networks[C]//Proceedings of the IEEE International Conference on Computer Vision. USA: IEEE, 2017: 764-773.

作者简介:



宣扬(1997-),男,硕士研究生,研究方向:机器学习与流体力学, E-mail: 564394806@qq.com。



吕宏强(1977-),男,博士,教授,研究方向:计算流体力学, E-mail: hongqiang.lu@nuaa.edu.cn。



安慰(1994-),男,博士,研究方向:计算流体力学, E-mail: anwei@nuaa.edu.cn。



刘学军(1976-),通信作者,女,博士,教授,研究方向:机器学习与流体力学、机器学习与生物医学, E-mail: xuejun.liu@nuaa.edu.cn。

(编辑:张黄群)