

## 基于几何适应与多尺度门控融合的二维障碍物流场预测

樊帅<sup>1</sup>, 陈永辉<sup>1</sup>, 谯旭<sup>2</sup>, 肖立伟<sup>1</sup>

(1. 西南科技大学计算机科学与技术学院, 四川 绵阳 621010; 2. 山东大学控制科学与工程学院, 山东 济南 250100)

**摘要:** 二维(2D)障碍物流场研究主要利用数值计算模拟流体运动, 模型的网格划分粒度、求解器算法、边界条件等因素对计算结果精度、计算资源和时间有着重要影响。由流场数据训练得到的深度学习模型, 能够用于实时或大规模流场的快速预测和推断任务, 并明显降低计算成本。但现有的深度学习模型在预测 2D 流场时, 为满足卷积操作, 需要对流场数据进行重采样, 将原本分布不均匀的网格变成均匀分布的网格, 造成特征丢失, 从而显著影响预测精度。针对这一问题, 提出一种对几何形状具有动态自适应能力的卷积神经网络模型 CAM-UNet。采用内容感知混合器(CAMixer)模块增强 U-Net 模型对几何形状的动态适应能力, 提高受重采样影响的网格点区域的流场预测精度。设计一种带门控单元的、能够有效融合数据空间特征和通道特征的模块, 基于此模块重构 U-Net 模型的跳跃连接结构, 进一步增强模型的特征表达能力。实验结果表明, 该模型能够更好地学习 2D 障碍物流场输入数据与流体  $x$ 、 $y$  方向速度的非线性表示, 能够明显降低具有复杂流动现象区域的水平方向速度预测误差。

**关键词:** 计算流体力学; 深度学习; U-Net; 通道注意力; 空间注意力

**源代码链接:** <https://github.com/fanshuai/CAM-UNet>

**中图分类号:** TP391

**文献标志码:** A

**DOI:** 10.19678/j.issn.1000-3428.0070352

## 2D Obstacle Flow Field Prediction Based on Geometry Adaptation and Multi-Scale Gated Fusion

FAN Shuai<sup>1</sup>, CHEN Yonghui<sup>1</sup>, QIAO Xu<sup>2</sup>, XIAO Liwei<sup>1</sup>

(1. School of Computer Science and Technology, Southwest University of Science and Technology, Mianyang 621010, Sichuan, China;

2. School of Control Science and Engineering, Shandong University, Jinan 250100, Shandong, China)

**【Abstract】** The research on 2-Dimensional (2D) obstacle flow fields primarily employs numerical computations to simulate fluid motion. Factors such as mesh granularity in the model, solver algorithms, and boundary conditions significantly affect the accuracy of the computational results, as well as the computational resources and time required. Deep learning models trained on flow field data can be utilized for rapid prediction and inference tasks in real-time or large-scale flow fields, thereby substantially reducing computational costs. However, when predicting 2D flow fields, existing deep learning models require the resampling of flow field data to satisfy convolutional operation requirements, transforming originally unevenly distributed meshes into uniformly distributed meshes. This process results in feature loss, which significantly affects prediction accuracy. To address this issue, a convolutional neural network model called CAM-UNet with dynamic geometric adaptability is proposed. A Content-Aware Mixer (CAMixer) module is employed to enhance the dynamic adaptability of the U-Net model to geometric shapes and improve the flow field prediction accuracy in mesh point regions affected by resampling. Additionally, a module with gating units capable of effectively integrating the spatial and channel features of the data is designed. Based on this module, the skip connection structure of the U-Net model is reconstructed to further enhance its feature representation capability. Experiments reveal that this model shows improvement in terms of learning the nonlinear representations between the input data of 2D obstacle flow fields and the fluid velocities in the  $x$  and  $y$  directions, significantly reducing prediction errors in the horizontal velocity for regions with complex flow phenomena.

**【Key words】** Computational Fluid Dynamics (CFD); deep learning; U-Net; channel attention; spatial attention

## 0 引言

在流体力学中, 二维(2D)障碍物流场主要研究

流体绕过 2D 障碍物时的流动情况和特性, 例如空气流过飞机机翼、汽车车身等 2D 模型时的流动特性, 以优化设计和减少阻力, 主要利用数值计算方法

**基金项目:** 国家自然科学基金(62101467); 四川省科技厅重点研发计划(2021YFG0031)。

**作者简介:** 樊帅(CCF 学生会员), 男, 硕士研究生, 主研方向为深度学习; 陈永辉(CCF 会员、通信作者)、谯旭, 副教授、博士; 肖立伟, 硕士研究生。

**收稿日期:** 2024-09-10

**修回日期:** 2025-01-09

**E-mail:** cyhmy@mail.ustc.edu.cn

来模拟流体运动,通过求解流体流动控制方程来预测流场的流动特性,计算精度取决于模型的网格划分、求解器算法、边界条件、计算参数等因素,同时需要大量的计算资源和时间。

近年来,深度学习在计算机视觉、自然语言处理、语音识别等领域取得了显著成就,研究人员开始探索将深度学习方法与计算流体动力学(CFD)相结合,用于改进传统 CFD 模拟的速度和准确性。基于深度学习的方法可以在不依赖物理方程显式描述的情况下,通过大量的流场数据训练模型,学习复杂模式和特征,从而加速流场求解并提高边界条件的预测精度。

深度学习模型在预测 2D 流场时,为满足卷积操作所需矩阵数据,需要对原始网格进行重采样,这种操作干预了原本分布不均匀的网格点,导致数据特征丢失,从而严重影响模型对几何表面附近复杂流场结构的预测精度。针对这一问题,本文提出了一种基于几何适应与多尺度门控融合的卷积网络模型 CAM-UNet。使用内容感知混合器(CAMixer)模块,根据输入内容动态分配计算路径,以增强模型对几何形状的动态适应能力;设计门控融合空间与通道特征的模块(GSC),替换 U-Net 的跳跃连接结构,进一步提升特征的提取质量,从而捕捉更加完整的流场结构细节。

## 1 相关工作

多层感知机(MLP)<sup>[1-5]</sup>在超燃冲压发动机进气道内的黏性超音速流场预测、翼型周围不可压缩定常流场预测等方面取得了较好的效果,但在预测流场时以向量作为输入,不能表现网格的空间分布,对网格的全局特征表达能力不足。文献[6]针对低保真度输入数据与训练数据偏差较大情况下重构高保真数据模型时精度显著下降的问题,提出一种基于已知偏微分方程中物理条件信息的扩散模型,该模型能够对不同输入源的 2D 湍流产生精度较高的重构结果。文献[7]提出了一种基于编码器-解码器结构的多尺度图神经网络模型,对翼型和圆柱体流等复杂流体的预测误差明显低于只使用图卷积的基线模型。文献[8]针对现有流场预测模型精度与泛化能力不足的问题,提出了一种先验变分自编码器的深度网络模型,将翼型在某一自由流条件下的流场数据作为先验参考,预测该翼型在其他自由流条件下的流场数据。文献[9]使用编码器-解码器结构卷积神经网络预测流场数据计算气动系数,以解决翼型跨声速流的计算流体动力学模拟耗时的问题。文

献[10]提出了一种基于实验纹影图像的速度场预测深度学习模型,成功实现了马赫数 1.8~2.4 范围内的速度场预测。文献[11]使用一种卷积神经网络-反卷积神经网络的模型,预测飞机翼型周围不可压缩流。文献[12]使用 U-Net<sup>[13]</sup> 架构卷积神经网络模型预测翼型流场,并探究了模型参数数量和训练数据量对模型性能的影响。文献[14]在 U-Net 的解码器上引入通道注意力机制,并且实现了在计算平面上直接使用 CNN 预测流场。文献[15]用 Transformer 的编码器替换跳跃连接结构,而文献[16]通过增加卷积块、下采样层、跳跃连接和上采样层的方式,增强模型的特征提取能力。文献[17]使用基于 U-Net 架构的三解码器深度卷积神经网络(DeepCFD)预测 2D 障碍物流场,DeepCFD 模型的输入是 3 个通道的数据,拥有 3 个解码器,用于输出流场数据的 3 个预测变量,每个预测变量都有一组独立的网络参数,既降低了预测变量之间的耦合,又提升了模型的泛化能力。文献[18]和文献[19]基于卷积神经网络分别实现了翼型流场和 2D 客车流场预测。

由于流场结构会随着障碍物几何形状的改变而发生剧烈变化,CFD 计算时需要使用非均匀分布网格提高计算精度。例如,翼型前端、末端形状变化显著的区域通常具有更复杂的流动现象,需要使用密集的网格以获得更高的模拟精度,形变较小的区域则使用相对稀疏的网格,如图 1 所示(彩色效果见《计算机工程》官网 HTML 版,下同),黑色点表示 CFD 计算的网格点分布。而基于深度学习的算法因卷积操作,需要使用固定大小的矩阵,必须对流场数据进行重采样,将原本非均匀分布的网格转换为均匀网格,原始流场数据利用符号距离函数(SDF)生成 2D 距离场,并通过数值标记不同的流动区域,使用 2D 距离场和区域标识作为卷积神经网络的输入信息,图 1 中红色网格代表重采样网格,因特征数据缺失,导致模型难以捕捉这些区域的复杂流动现象,造成较大的计算误差。因此,需要采取专门的措施特别关注这些区域,使神经网络对这些位置进行额外学习,以增强网络的特征表达能力。在计算机视觉领域,空间注意力、通道注意力和可变形卷积<sup>[20]</sup>均能有效增强特征。

为了解决重采样流场造成特征丢失导致流场结构变化剧烈区域预测精度降低这一问题,本文使用内容感知混合器 CAMixer<sup>[21]</sup>和可变形卷积增强模型对几何形状的动态适应能力,设计门控融合空间与通道特征的模块 GSC,替换 U-Net 的跳跃连接结




图 1 翼型流场的重采样示意图

Fig.1 Schematic diagram of resampling in the airfoil flow field

构,提升靠近几何表面等受重采样影响的网格点区域的流场预测精度。实验证明,本文所提 CAM-UNet 模型在 2D 障碍物流场预测中能显著降低物体上下两侧水平速度的预测误差。本文的主要贡献如下:

1) 现有深度学习方法对流场重采样,导致模型难以捕获靠近几何体表面等网格点密集区域的流场变化,为此,本文使用 CAMixer 模块和可变形卷积增强模型对几何形变的动态适应能力,以适应障碍物大小、形状等几何变化,从而提高模型的预测精度。

2) 设计 GSC 模块,对空间和通道注意力进行

门控融合,通过将此模块替换 U-Net 的跳跃连接结构,使模型能够充分利用跳跃连接结构中丰富的特征信息,从而捕捉到更加完整的流场结构细节。

3) 对 CAM-UNet 和 DeepCFD 进行性能测试,并对 3 种不同 2D 形状的预测结果进行误差分析和相关性分析。结果表明,本文提出的模型在捕捉水平速度复杂流动区域方面表现出色。

## 2 CAM-UNet 模型

CAM-UNet 以三解码器的 U-Net 模型为主干,引入 CAMixer 和可变形卷积模块,并使用 GSC 模块替换跳跃连接结构,其结构如图 2 所示。CAM-UNet 主要包括编码器结构和解码器结构,编码器用于提取输入数据的特征,并逐渐减少特征图的尺寸,它由多个卷积层和最大池化操作组成。解码器部分用于恢复特征图的空间分辨率,同时逐步融合编码器中提取的特征,它由多个反卷积层和上采样操作组成,在第 2 层和第 4 层的跳跃连接后接入 GSC 模块,同时可以保存下采样后不同尺寸特征图的原始特征,能够获得更加丰富的特征信息。




图 2 模型的整体结构

Fig.2 The overall structure of the model

### 2.1 几何适应模块

#### 2.1.1 可变形卷积

在普通卷积中,卷积核的目的是提取输入物的特征,这些卷积核的尺寸和大小通常是固定的,对未知的变化适应性差。可变形卷积在普通卷积的基础上额外学习了一个偏移量,将这个偏移量作用于卷积核,不同位置的卷积核采样点会根据图像内容进行自适应地调整,从而适应具有不同尺度或者形状的物体,可变形卷积的示意图如图 3 所示。2D 形状

的多样性导致在几何表面或具有显著几何形变的位置上具有更加复杂的流动现象,而这些位置受重采样的影响也更显著。为了表达 2D 形状的几何特征,通常使用 SDF 来表示几何结构,这些特征已经在模型的输入数据中得到了体现。可变形卷积能够自动调整尺度或感受野,使卷积核的形态更贴合特征结构,并对几何形变具有较强的适应能力。因此,将可变形卷积应用于模型的头部,能够明显增强模型适应 2D 形状变化的能力。




图 3 可变形卷积示意图

Fig.3 Schematic diagram of deformable convolution

### 2.1.2 CAMixer

CAMixer 主要用于图像处理的超分辨率重构任务,它根据图像的区域内容,自适应地选择不同的处理方式,将包含丰富细节的复杂区域分配给自注意力机制,对于简单平滑的区域,则使用简单的卷积操作。在本文方法中,CAMixer 主要由预测器、注意力分支和卷积分支组成,其主体结构如图 2(a) 所示。

预测器生成的掩码能够根据输入内容区分出各个区域的复杂度,以达到分配计算路线的目的。预测器对于给定输入特征  $X \in \mathbb{R}^{C \times H \times W}$ ,首先通过逐点卷积投影到  $V \in \mathbb{R}^{C \times H \times W}$ ,全局预测器[图 2(a)中 Global Predictor]通过该投影值生成全局特征  $C_g$ ,并与投影值  $V$  以及线性位置编码  $C_w \in \mathbb{R}^{2 \times H \times W}$  一同送入预测器中,生成偏移矩阵  $\Delta p$ 、掩码 mask、空间注意力  $A_s$  和通道注意力  $A_c$ ,具体表达式如式(1)所示:

$$\begin{cases} F = f_{\text{head}}(C_1, C_g, C_w) \\ \hat{F} = f_{\text{reduce}}(F) \in \mathbb{R}^{\frac{HW}{M^2} \times M^2} \\ \Delta p = r \cdot f_{\text{offsets}}(F) \in \mathbb{R}^{2 \times H \times W} \\ m = \hat{F} W_{\text{mask}} \in \mathbb{R}^{\frac{HW}{M^2} \times 1} \\ A_s = f_{\text{sa}}(F) \in \mathbb{R}^{1 \times H \times W} \\ A_c = f_{\text{ca}}(F) \in \mathbb{R}^{C \times 1 \times 1} \end{cases} \quad (1)$$

式中: $r$  为标量,用于控制偏移量的范围; $f_{\text{reduce}}$  为普通的 2D 卷积层; $W_{\text{mask}}$  为线性层。

## 2.2 GSC 模块

文献[9-10,12,14]没有考虑空间注意力和通道注意力,或者只考虑了其中一个,难以捕获空间特征与通道特征之间的互补关系。使用多路径融合特征的方法<sup>[22-24]</sup>能够有效合并不同尺度之间的互补信息。因此,为了充分利用模型隐藏层的空间特征和通道特征,让模型重点关注网格点分布密集的区域

和流场结构发生剧烈变化的区域,本文设计的 GSC 模块对特征数据的通道特征和空间特征分别进行提取,然后将两条特征提取路径的输出结果输入到门控单元进行融合。

### 2.2.1 空间注意力机制

空间注意力机制主要使模型对于重要的区域或位置产生更多的关注,从而提高模型的性能。对于输入数据,空间注意力模块首先在通道维度上进行最大池化和平均池化得到 2 个单通道数据,连接后经过卷积操作等计算,得到空间注意力权重矩阵,将需要赋予空间权重的数据与空间注意力权重矩阵相乘得到被赋予空间权重的最终输出。对于特征数据  $F_s \in \mathbb{R}^{H \times W \times C}$  的空间注意力权重  $M_s$ ,计算如式(2)所示:

$$M_s = \sigma(f^{7 \times 7}([\text{AvgPool}_c(F_s); \text{MaxPool}_c(F_s)])) \quad (2)$$

式中: $\text{AvgPool}_c(\cdot)$  表示对通道维度的平均池化操作; $\text{MaxPool}_c(\cdot)$  表示对通道维度的最大池化操作; $f^{7 \times 7}$  表示卷积核大小为  $7 \times 7$  的卷积操作; $\sigma$  为 Sigmoid 激活函数。

### 2.2.2 通道注意力机制

通道注意力机制通过调整通道权重,强调或抑制特征图中的某些通道,提高模型对关键特征的敏感度。首先,通过全局平均池化对每个通道进行压缩;然后,通过一个两层的全连接网络生成通道权重,通过激励操作学习各个通道之间的相关性,通过 Sigmoid 函数将权重映射到 0~1 之间,与对应通道相乘,为通道赋予不同权重。对于特征数据  $F_c \in \mathbb{R}^{H \times W \times C}$  的通道注意力权重  $M_c$ ,计算如式(3)所示:

$$M_c = \sigma(\text{MLP}(\text{AvgPool}_s(F_c)) + \text{MLP}(\text{MaxPool}_s(F_c))) \quad (3)$$

式中: $\text{AvgPool}_s(\cdot)$  和  $\text{MaxPool}_s(\cdot)$  分别为空间维度的全局平均池化操作与全局最大池化操作; $\text{MLP}(\cdot)$  表示多层感知机。

### 2.2.3 特征增强路径

GSC 模块的输入为上一层卷积的输出结果和编码器对应层复制块在通道维度上的拼接结果,其结构如图 2(b)所示,图中 SE 表示通道注意力机制, SAM 表示空间注意力机制。在进行通道和空间特征增强之前,首先执行一个  $3 \times 3$  卷积操作,简单合并两部分特征数据,随后将卷积结果分别送入空间和通道特征增强路径分支。本文模型使用 GSC 模块重构跳跃连接结构,它将浅层网络的输出作为输入,网络分布的特征信息早已通过卷积操作存在于各个通道中,仅依靠空间注意力并不能充分利用特

殊区域的特征信息,因此,GSC 模块采用双路径融合方法,将空间和通道的特征信息同时整合到输出特征中。为了避免在增强特征的同时削弱原始的特征信息,GSC 模块不仅学习通道与空间特征之间的关联度,还学习它们与原始特征之间的相关度,使得模型能够灵活选取不同的特征信息。

空间增强路径包含一个空间注意力块和一个空洞卷积块,通道增强路径包含一个通道注意力块和一个  $1 \times 1$  卷积。空洞卷积是一种通过在卷积核中填充零来扩大卷积感受野的变体,能够捕获多尺度的上下文信息。根据特征图尺寸的变化,GSC 模块内的空洞卷积通过调整填充零的数量来获取不同的感受野,特征图尺寸越大,填充零的数量越多。 $1 \times 1$  卷积操作实现了跨通道的信息交互,能够学习通道之间的关系,从而进一步增强通道特征,提高网络的表达能力。经过通道和空间特征增强后的特征,被输入到门控单元,与原始特征进行各自信息的动态选择,最后 3 个门控单元输出的特征图进行逐点相加,得到最终的特征输出。通过这些操作,CAM-UNet 能够更有效地利用特征数据,并提升模型的特征提取能力和预测精度。

#### 2.2.4 门控单元

在神经网络中,门控机制<sup>[25]</sup>能够选择性地控制信息流动,它通过卷积操作和 Sigmoid 激活从特征数据中学习出一组参数用于选择有效的特征。这种门控机制用于融合空间特征和通道特征,将空间特征和通道特征中的有效特征进行增强。由于门控机制在本文中是用于融合空间和通道特征,因此本文使用的门控方法与原始的门控卷积不同。原始的门控卷积计算公式如式(4)所示:

$$\begin{cases} G_{y,x} = \sum \sum W_g \cdot I \\ F_{y,x} = \sum \sum W_f \cdot I \\ O_{y,x} = \phi(F_{y,x}) \odot \sigma(G_{y,x}) \end{cases} \quad (4)$$

式中: $I$  为输入特征图; $W_g$  和  $W_f$  表示对  $I$  进行的 2 次卷积操作; $\phi$  和  $\sigma$  分别为激活函数(可以是 ReLU、ELU、LeakyReLU)和 Sigmoid 函数,2 次卷积结果一部分使用  $\phi$  激活函数激活,另一部分用  $\sigma$  将其值限制在 0~1 之间,最后将 2 个运算结果进行对应元素相乘,得到最终输出。本文的门控方法表示为:

$$\begin{cases} G_{y,x} = \sigma(f^{3 \times 3}(x_1 + x_2)) \\ O_{y,x} = \\ [\sigma_{\text{ELU}}(x_1) \times G_{y,x}; \sigma_{\text{ELU}}(x_2) \times (1 - G_{y,x})] \end{cases} \quad (5)$$

式中: $x_1$  与  $x_2$  表示进行门控融合的特征。

两部分特征对应点相加得到用于学习门控值的数据,经过卷积核尺寸为 3 的卷积  $f^{3 \times 3}$  与 Sigmoid 激活函数  $\sigma$ ,得到用于选择特征信息的门控值  $\sigma_{\text{ELU}}$ 。然后, $x_1$  与  $x_2$  通过  $\sigma_{\text{ELU}}$  激活后分别与  $G_{y,x}$  和  $(1 - G_{y,x})$  相乘进行特征的动态选择,并将两部分特征在通道上进行拼接,从而实现空间与通道的特征融合。

### 2.3 CAM-UNet 的编码器-解码器结构

通常的编码器-解码器结构只包含一个编码器和解码器。为了降低被预测值之间的耦合度,CAM-UNet 采用了三解码器的结构,解码器采用一致的网络结构,并分别预测流场中水平速度、垂直速度和压强的值,具体结构如表 1 所示。由于输入数据在被编码器处理之前保存着完整的几何结构信息,因此本文方法在编码器部分引入了可变形卷积与 CAMixer,使得模型能够第一时间处理这些几何形状并用于后续网络层的运算,从而提升了模型对几何形变的动态适应能力。GSC 模块的作用是增强并融合通道特征与空间特征,以获得更加丰富的特征信息,而跳跃连接结构是编码器特征与解码器特征的交汇处,这里的特征既保存了原始输入数据的细节,又拥有深层网络提取到的语义信息,适用于特征的增强与融合。

## 3 实验结果与分析

### 3.1 实验配置

实验平台搭载 NVIDIA RTX 2060 显卡,显存 8 GB,深度学习框架使用 PyTorch。在模型的训练过程中,训练超参数包括初始学习率、批量大小、优化器、训练次数,且都保持一致,各个模型使用的训练集和验证集为同一批。为了防止引入额外模块后模型在训练过程中出现过拟合,本文模型训练中的学习率是采用余弦动态调整的,学习率从初始值逐步衰减到一个不小于 0 的数,直到模型迭代完成。模型训练配置参数如表 2 所示,其中, $T_{\text{max}}$  和  $\eta_{\text{min}}$  是学习率余弦调整方法的超参数,分别表示学习率变化的最大周期和学习率不低于的最小值,weight\_decay 是优化器 AdamW 的超参数,用于设置权重衰减率以防止过拟合。

所有模型使用的损失函数都相同,结合了 3 个输出的误差,速度分量使用均方误差函数,压力分量使用平均绝对误差函数,并对每一个损失都进行了归一化,以平衡模型对每个物理量的优化。速度水平分量和垂直分量的损失函数表示为式(6):

表 1 CAM-UNet 网络层结构  
Table 1 CAM-UNet network layer structure

| 模块                 | 层类型                                       | 输入尺寸                       | 输出尺寸                       |
|--------------------|-------------------------------------------|----------------------------|----------------------------|
| Encoder Block      | Conv2D, $K=5$ , Str 为 1, Pad 为 2          | $N \times H \times W$      | $M \times H \times W$      |
|                    | Conv2D, $K=5$ , Str 为 1, Pad 为 2          | $M \times H \times W$      | $M \times H \times W$      |
|                    | Conv2D, $K=5$ , Str 为 1, Pad 为 2          | $M \times H \times W$      | $M \times H \times W$      |
| Decoder Block      | ConvTransPose2D, $K=5$ , Str 为 1, Pad 为 2 | $N \times H \times W$      | $M \times H \times W$      |
|                    | ConvTransPose2D, $K=5$ , Str 为 1, Pad 为 2 | $M \times H \times W$      | $M \times H \times W$      |
|                    | ConvTransPose2D, $K=5$ , Str 为 1, Pad 为 2 | $M \times H \times W$      | $C \times H \times W$      |
| Encoder            | DeformableConv                            | $3 \times H \times W$      | $3 \times H \times W$      |
|                    | CAMixer                                   | $3 \times H \times W$      | $13 \times H \times W$     |
|                    | Conv2D, $K=1$ , Str 为 1, Pad 为 0          | $16 \times H \times W$     | $3 \times H \times W$      |
|                    | Encoder Block 1, $N=3, M=8$               | $3 \times H \times W$      | $8 \times H \times W$      |
|                    | MaxPool, $K=2$ , Str 为 2                  | $8 \times H \times W$      | $8 \times H/2 \times W/2$  |
|                    | Encoder Block 2, $N=8, M=16$              | $8 \times H/2 \times W/2$  | $16 \times H/2 \times W/2$ |
|                    | MaxPool, $K=2$ , Str 为 2                  | $16 \times H/2 \times W/2$ | $16 \times H/4 \times W/4$ |
|                    | Encoder Block 3, $N=16, M=32$             | $16 \times H/4 \times W/4$ | $32 \times H/4 \times W/4$ |
|                    | MaxPool, $K=2$ , Str 为 2                  | $32 \times H/4 \times W/4$ | $32 \times H/8 \times W/8$ |
|                    | Encoder Block 4, $N=32, M=32$             | $32 \times H/8 \times W/8$ | $32 \times H/8 \times W/8$ |
| Decoder $\times 3$ | Decoder Block 1, $N=64, M=32, C=32$       | $64 \times H/8 \times W/8$ | $32 \times H/8 \times W/8$ |
|                    | MaxUnPool, $K=2$ , Str 为 2                | $32 \times H/8 \times W/8$ | $32 \times H/4 \times W/4$ |
|                    | GSC                                       | $32 \times H/4 \times W/4$ | $32 \times H/4 \times W/4$ |
|                    | Decoder Block 2, $N=64, M=32, C=16$       | $64 \times H/4 \times W/4$ | $16 \times H/4 \times W/4$ |
|                    | MaxUnPool, $K=2$ , Str 为 2                | $16 \times H/4 \times W/4$ | $16 \times H/2 \times W/2$ |
|                    | Decoder Block 3, $N=32, M=16, C=8$        | $32 \times H/2 \times W/2$ | $8 \times H/2 \times W/2$  |
|                    | MaxUnPool, $K=2$ , Str 为 2                | $8 \times H/2 \times W/2$  | $8 \times H \times W$      |
|                    | GSC                                       | $8 \times H \times W$      | $8 \times H \times W$      |
|                    | Decoder Block 4, $N=16, M=8, C=1$         | $16 \times H \times W$     | $1 \times H \times W$      |
|                    |                                           |                            |                            |

表 2 模型训练参数配置  
Table 2 Configuration of model training parameters

| 配置参数          | DeepCFD | 本文模型  |
|---------------|---------|-------|
| Learning Rate | 0.001   | 0.001 |
| Batch Size    | 64      | 64    |
| Optimizer     | AdamW   | AdamW |
| weight_decay  | 0.005   | 0.005 |
| Epoch         | 1 000   | 1 000 |
| T_max         | —       | 1 000 |
| eta_min       | —       | 0     |
| 训练集和验证集划分比例   | 7:3     | 7:3   |

$$L_u = \sum_{i=1}^N \sum_{j=1}^H \sum_{k=1}^W (y_{\text{pred}} - y_{\text{ture}})^2 \quad (6)$$

压强分量的损失函数表示为式(7):

$$L_p = \sum_{i=1}^N \sum_{j=1}^H \sum_{k=1}^W |y_{\text{pred}} - y_{\text{ture}}| \quad (7)$$

式中:  $N$  表示样本数;  $H$  和  $W$  分别表示输出数据高度和宽度;  $y_{\text{pred}}$  表示预测值;  $y_{\text{ture}}$  表示真实值。每个

模型都设置了早停机制,以保存训练过程中最优的模型参数。

### 3.2 训练数据集与评估指标

数据集使用 DeepCFD 提供的包含 981 个不同形状的 2D 障碍物数据,该数据集已经将流场数据重采样为数据点均匀分布的矩阵数据。其中,输入神经网络的数据包含障碍物和计算域边界的 SDF<sup>[26]</sup>、流动区域信息 3 个通道,真实流场数据通过 OpenFOAM 求解,图 4 为输入数据与输出数据的形状图,其中,  $U_x$ 、 $U_y$  和  $P$  分别表示流场的水平速度、垂直速度以及压强。在 2D 障碍物流场研究中,水平速度反映流体的主流向运动趋势,垂直速度揭示流体在障碍物附近的偏转和分离现象,压强反映流体在不同位置的能量分布,有助于分析流体的受力情况。流体从左侧区域流入,经过障碍物后从右侧区域流出,当流体到达障碍物时,会在障碍物上下两侧分离,产生复杂的流动变化。




图 4 输入数据与输出数据的形状

Fig.4 The shape of input data and output data

由 SDF 计算出 CFD 网格中各个点到 2D 障碍物边界和计算域边界的距离,即图 4 中的 SDF 1,计算公式如式(8)所示:

$$\text{SDF}(x) = \begin{cases} d(x, \partial\Omega), & x \in \Omega \\ -d(x, \partial\Omega), & x \in \Omega^c \end{cases} \quad (8)$$

式中: $\Omega$  表示障碍物外部网格位置; $d$  为网格位置  $x$  到  $\Omega$  的距离; $\partial\Omega$  为  $\Omega$  的边界。障碍物内部的网格位置  $\Omega^c$  被设置为负距离。对于任意的  $x \in \Omega$ ,其距离可以表示为式(9):

$$d(x, \partial\Omega) := \inf_{y \in \partial\Omega} d(x, y) \quad (9)$$

图 4 中 SDF 2 描述流动域中心沿垂直方向的距离变化,越靠近边缘的距离值越小,越靠近中心的距离值越大。

对于水平速度、垂直速度和压强 3 种不同的物理量,实验采取了均方误差(MSE,  $M_{\text{MSE}}$ )来评估模

型的流场预测精度。MSE 的值越低,说明预测结果与 CFD 真实值之间的差距越小,预测更准确。MSE 的计算方式如式(10)所示:

$$M_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N (y_i^{\text{pred}} - y_i^{\text{ture}})^2 \quad (10)$$

式中: $y_i^{\text{pred}}$  是第  $i$  个样本的预测值,如水平速度、垂直速度或压强; $y_i^{\text{ture}}$  是第  $i$  个样本的真实值。

表 3 对比了本文模型与单解码器的自动编码器(AE-1)、三解码器的自动编码器(AE-3)、单解码器的 U-Net (UNet-1) 和三解码器的 U-Net (DeepCFD) 4 种模型在 2D 障碍物流场数据集上的水平速度、垂直速度和压强的均方误差指标结果。可以看出,单解码器的自动编码器 AE-1 的各项 MSE 最大,而结构逐渐优化的三解码器 AE-3、一解码器 UNet-1 和三解码器 DeepCFD 相对于 AE-1 模

表 3 本文模型与其他模型的对比分析

Table 3 Comparative analysis of this model with other models

| 模型       | MSE             |                 |                 |                 |
|----------|-----------------|-----------------|-----------------|-----------------|
|          | $U_x$           | $U_y$           | $P$             | Total           |
| AE-1     | 2.151 3±0.168 8 | 0.627 0±0.061 1 | 1.719 8±0.005 2 | 4.498 1±0.175 3 |
| AE-3     | 1.785 4±0.117 5 | 0.295 6±0.004 5 | 1.212 5±0.015 0 | 3.293 5±0.117 1 |
| UNet-1   | 1.116 9±0.139 3 | 0.332 6±0.012 1 | 1.470 8±0.004 5 | 2.920 3±0.152 0 |
| DeepCFD  | 0.773 0±0.089 7 | 0.215 3±0.018 6 | 1.042 0±0.043 1 | 2.030 3±0.136 0 |
| CAM-UNet | 0.646 4±0.058 0 | 0.187 6±0.005 8 | 1.000 2±0.008 7 | 1.834 1±0.066 3 |

型性能有一定提高。对于本文提出的模型,在速度和压强的均方误差方面都取得了更好的效果,尤其是在水平速度的效果提升上更加明显。

为了进一步探究 CAM-UNet 对 2D 流场的预测能力,选择 DeepCFD 作为主要对比模型。在实验中对 DeepCFD 进行复现,训练结果均达到了复现标准。表 4 中的实验结果表明,在水平速度的 MSE 中,CAM-UNet 取得了比 DeepCFD 更好的结果,而垂直速度和压强的 MSE 没有明显提升。

表 4 2 种模型的预测能力对比

Table 4 Comparison of predictive abilities between two models

| 模型       | 序号  | MSE       |           |           |           |
|----------|-----|-----------|-----------|-----------|-----------|
|          |     | $U_x$     | $U_y$     | $P$       | Total     |
| DeepCFD  | 1   | 0.748 828 | 0.206 861 | 1.015 464 | 1.971 153 |
|          | 2   | 0.724 492 | 0.196 051 | 0.996 810 | 1.917 353 |
|          | 3   | 0.682 873 | 0.190 644 | 1.000 392 | 1.873 909 |
|          | 平均值 | 0.718 731 | 0.197 852 | 1.004 222 | 1.920 805 |
| CAM-UNet | 1   | 0.654 873 | 0.185 328 | 1.003 104 | 1.843 305 |
|          | 2   | 0.633 573 | 0.185 894 | 0.989 072 | 1.808 539 |
|          | 3   | 0.630 959 | 0.185 950 | 1.011 850 | 1.828 759 |
|          | 4   | 0.736 196 | 0.197 640 | 1.002 274 | 1.936 110 |
|          | 5   | 0.576 391 | 0.183 023 | 0.994 546 | 1.753 960 |
|          | 平均值 | 0.646 398 | 0.187 567 | 1.000 169 | 1.834 134 |

为直观地比较 2 种模型预测流场的能力,将 293 个测试样例分别在 DeepCFD 和 CAM-UNet 上运行,将预测结果与 CFD 真实值之间的绝对误差逐像素点相加,并在折线图上绘制出误差值分布。2 种模型的水平速度误差值对比如图 5 所示,结果说明,对于水平速度,CAM-UNet 比 DeepCFD 有更好的预测能力。




图 5 CAM-UNet 与 DeepCFD 在测试集上的水平速度绝对误差分布

Fig.5 Distribution of absolute horizontal velocity error between CAM-UNet and DeepCFD on the test set

为了验证 CAMixer 和 GSC 模块的有效性,本文在 CAM-UNet 的基础上分别对 CAMixer 模块和 GSC 模块进行消融实验,结果如表 5 所示。通过对

比各项指标可以得出,去掉 CAMixer 或 GSC 模块后都会使模型精度下降,这表明 2 个模块都能有效提升模型的精度,同时引入 CAMixer 和 GSC,能够获得更好的性能。

表 5 消融实验结果

Table 5 Ablation experiment results

| 指标        | CAM-UNet        | 去除 GSC          | 去除 CAMixer      |
|-----------|-----------------|-----------------|-----------------|
| $U_x$ MSE | 0.646 4±0.058 0 | 0.680 9±0.049 8 | 0.653 0±0.021 4 |
| $U_y$ MSE | 0.187 6±0.005 8 | 0.202 2±0.016 7 | 0.195 0±0.005 8 |
| $P$ MSE   | 1.000 2±0.008 7 | 1.006 2±0.014 4 | 1.007 9±0.009 6 |
| Total MSE | 1.834 1±0.066 3 | 1.889 3±0.062 8 | 1.855 9±0.017 2 |

### 3.3 流场预测结果对比和误差分析

为对比模型的预测效果,重新选取了 3 种不同形状的 2D 障碍物作为测试对象,这些测试用例没有参与模型训练。

方形障碍物的流场预测效果如图 6 所示,流场在方形障碍物的前端边缘诱导出高压区域,并且在到达障碍物的前端顶点后立即分离,垂直速度  $U_y$  和压强  $P$  分布变化均很好地捕捉到了这种改变。但结合模型对方形障碍物预测结果与 CFD 结果之间的绝对误差值对比,如图 7 所示,可以明显看出,在水平速度  $U_x$  上下两侧区域的预测中,DeepCFD 预测不够精细,形状不完整且细节较为模糊,而 CAM-UNet 对于该区域的预测形状更完整和清晰,能够得到更高的精度且误差区域的范围明显缩小,且误差减小最多的区域对应于图 6 中障碍物下侧的分离流,表明本文模型对复杂流动域的细节恢复能力更强。

圆形障碍物的流场预测效果如图 8 所示,在其前缘产生了一个圆形的高压区域,流场在到达障碍物中部时从顶部和底部产生分离,结合图 9 可以看出,在水平速度中靠近障碍物上下两侧高速区域,DeepCFD 呈现不平滑和割裂感,而 CAM-UNet 预测结果更流畅平滑。在具有复杂流动的右半区域,CAM-UNet 不仅能够准确地捕捉这些流动特征,并且明显减少了障碍物上侧分离流的预测误差,对于水平速度梯度变化较大的区域,具有较强的捕获能力。

菱形障碍物的流场预测效果如图 10 所示,流场在其前端顶点形成了一个相对较小的高压区域,然后发生了流动分离。在水平速度的高速度区域,DeepCFD 在该区域只预测出了一部分,与 CFD 结果相比不够完整,结合图 11 的绝对误差值对比分析可以看出,DeepCFD 在障碍物上下两侧的分离流中




图 6 方形障碍物流场预测结果

Fig.6 Prediction results of square obstacle flow field




图 7 方形障碍物流场预测的绝对误差

Fig.7 Absolute error of prediction for square obstacle flow field

均产生了明显的误差,而 CAM-UNet 不仅能够完整地反映出其流动细节和层次结构,而且在水平速度梯度变化剧烈的分离流中,误差范围和幅度明显小于 DeepCFD。

在图 6、图 8、图 10 中,模型预测结果与 CFD 计算结果的相似程度,直接反映了模型捕捉流场流动规律的能力。在图 7、图 9、图 11 中,一般把 CFD 计算结果作为真实流场,越明亮的位置表示




图 8 圆形障碍物流场预测结果

Fig.8 Prediction results of circular obstacle flow field




图 9 圆形障碍物流场预测的绝对误差

Fig.9 Absolute error of prediction for circular obstacle flow field

误差越大。

CAM-UNet 和 DeepCFD 均能反映流场的宏观趋势,例如分离尾迹、垂直速度和压力的分布变化,与 CFD 计算结果吻合较好。但在流动分离、物

体表面流场梯度变化较大等复杂区域,DeepCFD 受流场重采样的影响而出现了明显误差,CAM-UNet 通过内容感知混合器和可变形卷积对这些区域进行了额外的学习,并使用 GSC 模块对特征




图 10 菱形障碍物流场预测结果

Fig. 10 Prediction results of diamond-shaped obstacle flow field




图 11 菱形障碍物流场预测的绝对误差

Fig. 11 Absolute error of prediction for the diamond-shaped obstacle flow field

进行空间和通道尺度的融合,使其在这些位置的误差明显减少。误差分析的结果表明,本文提出的模型能够关注到这些复杂流场的变化,从而获得更高的预测精度。

### 3.4 相关性分析

为了评估模型在预测 3 种障碍物水平速度方面的精度提升效果,采用皮尔森相关性系数来量化预测结果与 CFD 模拟结果之间的线性关系。由于预

测结果和 CFD 模拟结果均以形状大小相同的矩阵形式存在,因此在计算皮尔森相关性系数时,所涉及的变量(即像素点个数)是完全一致的,而相关性散点图将预测结果和 CFD 模拟结果的像素值用于散点的坐标定位,可以较好地反映预测值与 CFD 模拟结果的异常偏离情况,有助于识别数据中的异常值或模型表现不佳的特定区域。本文针对 DeepCFD 和 CAM-UNet 分析了流场预测结果与真实值的相关性,使用皮尔森相关性系数来衡量预测值与真实值之间的相关性。皮尔森相关性系数的计算如式(11)所示:

$$R = \frac{\sum (f_i^t - \bar{f}^t)(f_i^p - \bar{f}^p)}{\sqrt{\sum (f_i^t - \bar{f}^t)^2} \sqrt{\sum (f_i^p - \bar{f}^p)^2}} \quad (11)$$

式中: $f_i^t$  和  $f_i^p$  分别为真实值的像素和预测值的像

素; $\bar{f}^t$  和  $\bar{f}^p$  分别为真实像素与预测像素的平均值。相关性系数衡量线性相关度,它的绝对值越趋近于 1,则相关性越强。

图 12~图 14 为 DeepCFD 和 CAM-UNet 对 3 种形状障碍物流场的预测结果与真实值之间逐像素相关性分析散点图,横坐标表示真实值的像素值大小,纵坐标表示预测值的像素值大小。 $R$  的值越大,各个像素点越集中于一条线上,且相关性也越强。在图 12~图 14 中,对于水平速度  $U_x$  的相关性系数,CAM-UNet 均比 DeepCFD 大,可以直接观察到,本文所提模型的散点分布更加集中,与真实值的相关性更强,且散点图中 CAM-UNet 靠近右上角的高数值点更为集中,该结果为前两节得出的 CAM-UNet 能够更加准确地捕获复杂流动现象的结论提供了有效证明。




图 12 方形障碍物流场预测结果与 CFD 真实值的相关性分析

Fig. 12 Correlation analysis between prediction results of square obstacle flow field and actual CFD values




图 13 圆形障碍物流场预测结果与 CFD 真实值的相关性分析

Fig. 13 Correlation analysis between predicted results of circular obstacle flow field and actual CFD values

### 3.5 模型推理时间

为了评估模型的推理效率,本文对比了 CAM-UNet 和 DeepCFD 的推理时间,对比结果如表 6 所示。模型输入随机生成的张量(该张量与训练集、验证集所使用的形状大小一致,均为  $3 \times 172 \times 79$ ),并执行 100 次推理循环,记录每次推理的时间,最终以

100 次循环的平均推理时间作为模型的推理速度指标,这个过程被重复进行 5 次,以获得更加精准的推理指标。从表 6 可以看出,2 种模型都能在极短的时间内完成推理。由于增加了特征增强模块,CAM-UNet 的推理速度有一定程度的下降,更高的精度通常意味着更高的计算成本,反映模型在精度




图 14 菱形障碍物流场预测结果与 CFD 真实值的相关性分析

Fig. 14 Correlation analysis between predicted results of diamond-shaped obstacle flow field and actual CFD values

与效率之间的权衡。

表 6 模型推理时间对比

Table 6 Comparison of model inference time 单位:ms

| 实验分组 | CAM-UNet | DeepCFD |
|------|----------|---------|
| 实验 1 | 18.78    | 10.21   |
| 实验 2 | 18.78    | 10.94   |
| 实验 3 | 18.52    | 11.13   |
| 实验 4 | 18.77    | 10.88   |
| 实验 5 | 18.65    | 10.89   |
| 平均值  | 18.70    | 10.81   |

## 4 结束语

现有基于深度学习的 CFD 模拟加速模型重新采样流场导致网格点密集区域的数据密度被弱化,使得靠近几何表面的位置与流场结构发生剧烈变化区域的预测精度受到显著影响,针对这一问题,本文提出了一种对几何形状具有动态自适应能力的卷积神经网络模型 CAM-UNet。基于内容感知混合器 CAMixer 和可变形卷积,使模型能够根据几何形状自适应地学习复杂流动区域和简单流动区域的不同特征信息,同时,设计了一种替换跳跃连接结构的 GSC 模块,来增强并融合数据通道特征与空间特征。实验结果验证了本文所提方法对于提升流场预测精度的有效性。

在下一步的工作中,尝试使用其他 CFD 数据集并扩充样本的数量,将这些模型运用在其他场景(如翼型流场计算、超燃冲压发动机流场计算)中,以进行其他更复杂情况下的实验。此外,在深度学习领域,已经开发出了各种架构的模型,U-Net 架构只是其中一种,后续将继续探索深度学习领域中的不同架构,并与 CFD 相结合,以获得速度更快、精度更高的预测模型。

## 参考文献

- [1] FUJIO C, OGAWA H. Deep-learning prediction and uncertainty quantification for scramjet intake flowfields[J]. Aerospace Science and Technology, 2022, 130: 107931.
- [2] ZUO K J, YE Z Y, ZHANG W W, et al. Fast aerodynamics prediction of laminar airfoils based on deep attention network[J]. Physics of Fluids, 2023, 35(3): 037127.
- [3] WANG X, KOU J Q, ZHANG W W. Unsteady aerodynamic prediction for iced airfoil based on multi-task learning[J]. Physics of Fluids, 2022, 34(8): 087117.
- [4] SHAN X L, LIU Y L, CAO W B, et al. Turbulence modeling via data assimilation and machine learning for separated flows over airfoils[J]. AIAA Journal, 2023, 61(9): 3883-3899.
- [5] ZUO K J, BU S H, ZHANG W W, 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.
- [6] SHU D L, LI Z J, FARIMANI A B. A physics-informed diffusion model for high-fidelity flow field reconstruction[J]. Journal of Computational Physics, 2022, 478: 111972.
- [7] YANG Z S, DONG Y D, DENG X G, et al. AMGNET: multi-scale graph neural networks for flow field prediction[J]. Connection Science, 2022, 34(1): 2500-2519.
- [8] YANG Y J, LI R Z, ZHANG Y F, et al. Flowfield prediction of airfoil off-design conditions based on a modified variational autoencoder[J]. AIAA Journal, 2022, 60(10): 5805-5820.
- [9] DURU C, ALEMDAR H, BARAN O U. A deep learning approach for the transonic flow field predictions around airfoils[J]. Computers & Fluids, 2022, 236: 105312.
- [10] KONG C, WANG Z A, LI Y F, et al. A deep learning approach for velocity field prediction in a scramjet isolator from Schlieren images[J]. Chinese Journal of Aeronautics, 2023, 36(11): 58-70.
- [11] WU M Y, WU Y, YUAN X Y, et al. Fast prediction of flow field around airfoils based on deep convolutional neural network[J]. Applied Sciences, 2022, 12(23): 12075.
- [12] THUEREY N, WEIBENOW K, PRANTL L, et al. Deep learning methods for Reynolds-averaged navier-stokes simulations of airfoil flows[J]. AIAA Journal, 2020, 58(1): 25-36.
- [13] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation [EB/OL]. [2024-08-05]. <https://arxiv.org/abs/1505.04597>.

- [14] HU J W, ZHANG W W. Flow field modeling of airfoil based on convolutional neural networks from transform domain perspective[J]. Aerospace Science and Technology, 2023, 136: 108198.
- [15] WANG H N, CAO P, WANG J Q, et al. UCTransNet: rethinking the skip connections in U-Net from a channel-wise perspective with Transformer[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2022, 36(3): 2441-2449.
- [16] 刘帅, 葛浙东, 刘晓彤, 等. 改进 UNet++ 的杉木 CT 图像年轮分割[J]. 计算机工程与应用, 2024, 60(5): 232-239.  
LIU S, GE Z D, LIU X T, et al. Improved UNet++ for tree rings segmentation of Chinese fir CT images [J]. Computer Engineering and Applications, 2024, 60(5): 232-239. (in Chinese)
- [17] RIBEIRO M D, REHMAN A, AHMED S, et al. DeepCFD: efficient steady-state laminar flow approximation with deep convolutional neural networks [EB/OL]. [2024-08-05], <https://arxiv.org/abs/2004.08826>.
- [18] BHATNAGAR S, AFSHAR Y, PAN S W, et al. Prediction of aerodynamic flow fields using convolutional neural networks[J]. Computational Mechanics, 2019, 64(2): 525-545.
- [19] GARCIA-FERNANDEZ R, PORTAL-PORRAS K, IRIGARAY O, et al. CNN-based flow field prediction for bus aerodynamics analysis[J]. Scientific Reports, 2023, 13: 21213.
- [20] DAI J F, QI H Z, XIONG Y W, et al. Deformable convolutional networks [C] // Proceedings of the IEEE International Conference on Computer Vision (ICCV). Washington D. C., USA: IEEE Press, 2017: 764-773.
- [21] WANG Y, LIU Y, ZHAO S J, et al. CAMixerSR: only details need more “attention” [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Washington D. C., USA: IEEE Press, 2024: 25837-25846.
- [22] 杨郅树, 梁佳楠, 曹永军, 等. 基于局部分离与多尺度融合的图像超分辨率重建[J]. 计算机工程, 2024, 50(7): 314-323.  
YANG Z S, LIANG J N, CAO Y J, et al. Image super-resolution reconstruction based on partial separation and multiscale fusion [J]. Computer Engineering, 2024, 50(7): 314-323. (in Chinese)
- [23] 赵婉秋, 张俊虎, 李海涛. 用于建筑物分割的平行结构特征融合网络[J]. 计算机工程, 2024, 50(8): 239-248.  
ZHAO W Q, ZHANG J H, LI H T. Feature fusion network with parallel structure for building segmentation [J]. Computer Engineering, 2024, 50(8): 239-248. (in Chinese)
- [24] 闵莉, 董冰洁, 安冬. 基于多注意力机制与跨特征融合的语义分割算法[J]. 计算机工程, 2024, 50(8): 282-289.  
MIN L, DONG B J, AN D. Semantic segmentation algorithm based on multi-attention mechanism and cross-feature fusion [J]. Computer Engineering, 2024, 50(8): 282-289. (in Chinese)
- [25] YU J H, LIN Z, YANG J M, et al. Free-form image inpainting with gated convolution [C] // Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). Washington D. C., USA: IEEE Press, 2019: 4470-4479.
- [26] GUO X X, LI W, IORIO F. Convolutional neural networks for steady flow approximation [C] // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York, USA: ACM Press, 2016: 481-490.

文字编辑 吴云芳  
栏目编辑 赖玉玲