AdaField：借助物理信息预训练与流动条件适配实现可泛化的表面压力建模

Junhong Zou[1,2], **Wei Qiu**[2,3], **Zhenxu Sun**[3], **Xiaomei Zhang**[1,2], **Zhaoxiang Zhang**[1], **Xiangyu Zhu**[1,2*]

[1] MAIS，中国科学院自动化研究所，北京，中国；[2] 中国科学院大学人工智能学院，北京，中国；[3] 中国科学院力学研究所流固耦合系统力学重点实验室，北京，中国 zoujunhong2022@ia.ac.cn, xiangyu.zhu@ia.ac.cn

arXiv:2601.07139v1 [cs.CE] 12 Jan 2026

摘要

包括汽车、列车和飞机在内的交通运输系统的表面压力场，对于空气动力学分析与设计至关重要。近年来，深度神经网络已成为建模表面压力场的一种高效且前景广阔的方法，可替代计算成本高昂的计算流体力学仿真。目前，汽车空气动力学等领域已有大规模公开数据集。然而，在高速列车等许多专业领域，数据稀缺仍是空气动力学建模面临的根本性挑战，严重限制了标准神经网络方法的有效性。为解决这一局限性，我们提出了自适应场学习框架（AdaField），利用公开的大规模数据集对模型进行预训练，从而提升其在数据有限子领域中的泛化能力。AdaField由两个关键组件构成。首先，我们设计了语义聚合点变换器（SAPT），作为一种高性能骨干网络，能够高效处理大规模点云，用于表面压力预测。其次，针对不同空气动力学子领域在流动条件和几何尺度方面存在的显著差异，我们提出了流动条件适配器（FCA）和物理信息数据增强（PIDA）。FCA使模型能够仅使用少量可训练参数，灵活适应不同的流动条件；PIDA则扩展了训练数据分布，以更好地覆盖物体尺度和速度的变化。我们的实验表明，AdaField在DrivAerNet++数据集上达到了最先进水平，并且只需进行少量微调，即可有效迁移至列车和飞机场景。这些结果凸显了AdaField作为一种可泛化、可迁移的表面压力场建模方案的潜力，能够支持广泛交通运输系统中的高效空气动力学设计。

代码— https://github.com/zoujunhong/UniField

引言

在汽车、列车和飞机等交通运输系统的空气动力学分析中，表面压力场

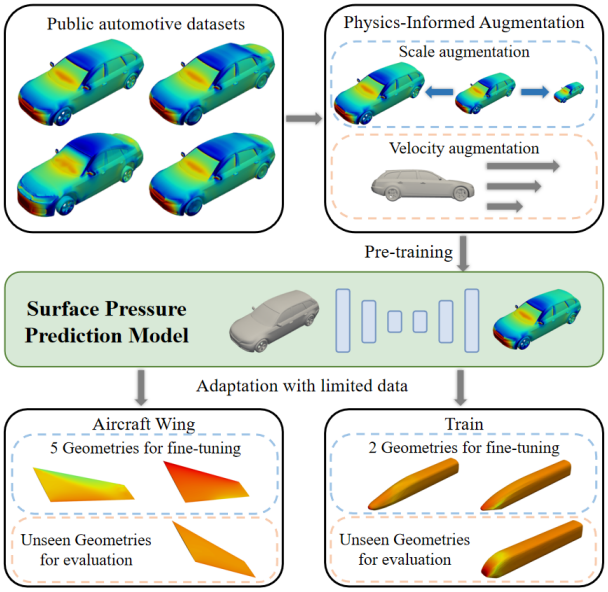


图 1：概览。AdaField 扩充了公开的汽车数据集，用于模型预训练，随后通过微调使模型能够适应其他数据有限的领域，例如飞机机翼和列车。

在确定升力、阻力、侧向力和倾覆力矩等关键物理量方面发挥着基础作用（Qiu et al. 2025）。准确捕捉高分辨率表面压力场，对于优化空气动力学性能、确保结构完整性、提高燃油效率以及应对其他实际问题至关重要（Gao et al. 2025）。传统上，表面压力场模拟通过计算流体力学（CFD）进行，但这种方法成本高、耗时长，且难以适用于现代交通运输系统中遇到的各种形状和流动条件所构成的广阔设计空间。

近年来，神经网络凭借从大型数据集学习复杂模式的能力，已成为表面压力建模中颇具前景且高效的替代方案（Chen 等，2025；Choy 等，2025；Wang et al. 2025；Elrefaie et al. 2025）。与计算流体动力学相比，后者通常需要数百个中央处理器小时来模拟压力场，而神经网络通常能在一秒内完成预测。然而，数据稀缺仍是大规模部署这些模型于空气动力学应用中的根本障碍。

*通讯作者 版权所有 © 2026，人工智能促进协会 (www.aaai.org)。保留所有权利。

尽管某些领域拥有大量公开数据集，尤其是汽车空气动力学领域（Elrefaie et al. 2025；Ashton 和 Maddix，2024；Ashton 等，2024b、2024a），但许多专业子领域，例如列车或飞机领域，仍缺乏充足的数据。这一局限严重制约了传统神经网络方法的效能。此外，不同交通方式在几何尺度和流动条件方面存在显著差异，进一步增加了模型泛化与迁移的难度。例如，汽车通常以行驶速度和风速作为输入，而飞机（Wang et al. 2025）通常使用马赫数（Ma）和攻角（AoA）；高速列车的速度和几何尺度则与汽车截然不同。因此，在一个领域预训练的模型直接应用于其他领域时往往表现不佳，这凸显了在数据稀缺条件下实现高效知识迁移与泛化方法的迫切需求。

为应对这些挑战，我们提出了自适应场学习框架（AdaField），该框架专注于在公共汽车数据集上对模型进行预训练，并将其适配到其他数据有限的子领域，如图 1 所示。AdaField 首先引入语义聚合点变换器（SAPT），将改编自点变换器（Zhao 等人，2021）的局部向量自注意力与改编自 Slot Attention（Locatello 等人，2020）的语义聚合模块相结合，作为高性能骨干网络，以高效提取几何特征。局部向量自注意力将注意力计算限制在 k近邻范围内，从而降低处理包含大量点的点云时的内存需求。语义聚合模块能够学习将点云分解为不同部分，捕捉复杂表面之间的结构共性。另一方面，为了提升跨域泛化能力，并应对不同交通运输系统之间流动条件和几何尺度存在的显著差异，AdaField 引入了两种互补策略。首先，基于适配器（Houlsby 等，2019）设计的流动条件适配器（FCA），通过一组轻量级可训练参数将特定流动信息注入模型，从而实现针对新空气动力学工况的高效微调。其次，我们采用基于纳维–斯托克斯方程（Constantin and Foiaş 1988）的物理信息数据增强（PIDA）策略，通过覆盖不同物体尺度和速度来扩展训练分布。FCA 与 PIDA 协同作用，使 AdaField 能够在数据稀缺条件下实现稳健的可迁移性和泛化能力。

我们通过在 DrivAerNet++(Elrefaie et al. 2025) 上开展实验，验证了 AdaField 的有效性。DrivAerNet 是一个公开的大规模汽车空气动力学计算流体力学数据集。我们的评估重点是表面压力场预测，AdaField 在多项标准指标上始终达到最先进水平。为进一步展示其跨域泛化能力，我们还在代表不同交通运输系统的另外两个数据集上评估了 AdaField：一个列车数据集（Qiu et al. 2025）和一个飞机机翼数据集（Wang et al. 2025）。在这些实验中，AdaField 首先在 DrivAerNet++ 上进行预训练，然后仅使用来自各目标域的少量样本进行微调。结果表明，AdaField 具有出色的小样本可迁移性，并能泛化至新的气动场景，凸显了其在汽车应用以外数据稀缺子域中的实际潜力。

总而言之，我们的主要贡献如下：

- 我们提出了 AdaField，这是一个用于预测交通运输系统表面压力场的框架。通过结合局部向量自注意力与语义聚合模块，该框架能够高效处理包含大量点的点云，并保持高性能预测。
- 我们开发了 FCA，以促进交通运输系统之间流动条件存在显著差异时的领域适应；此外，我们还提出了 PIDA，这是一种数据增强策略，可从物体尺度和速度两个方面扩展训练数据的多样性，从而实现对未见过的气动条件的泛化。
- 我们在 DrivAerNet++ 上取得了最先进水平的性能，并开展了全面的跨领域泛化研究。研究表明，在大规模汽车数据上预训练的 AdaField，只需极少量微调，便可有效适应列车和飞机场景，验证了其在数据匮乏环境下作为气动设计任务解决方案的实际潜力。

相关工作

表面压力预测

表面压力预测旨在根据车辆的几何形状和流动条件，推断其表面各处的压力分布。传统计算流体动力学软件通过在离散化的计算域上数值求解流体力学控制方程（如纳维–斯托克斯方程）来模拟表面场，但计算成本高昂，因此神经网络成为一种替代方案。DrivAer-Net++ （Elrefaie et al. 2025）是一个大规模空气动力学数据集，包含数千种汽车几何形状、计算流体动力学流场与压力场、参数化模型及气动系数，可支持汽车空气动力学领域的稳健训练与评估。该数据集还提出了 RegDCGNN（Elrefaie、Dai 和 Ahmed，2025），这是一种用于回归气动参数的动态图卷积神经网络，同时避免了渲染或符号距离函数预处理带来的开销。在后续工作中，Transolver（Wu 等，2024；Luo 等，2025）采用基于 Transformer 的偏微分方程求解器，并运用物理启发式切片注意力，将网格点归入可学习的物理状态切片，从而实现跨复杂几何形状的可扩展泛化。因子化隐式全局卷积（FIGConvNet）（Choy 等，2025）通过隐式因子化，高效学习三维网格上的全局交互，在保持精度的同时降低复杂度。TripNet（Chen 等，2025）将三维汽车几何形状编码为紧凑的三平面表示，从而能够逐点预测压力和完整流场。

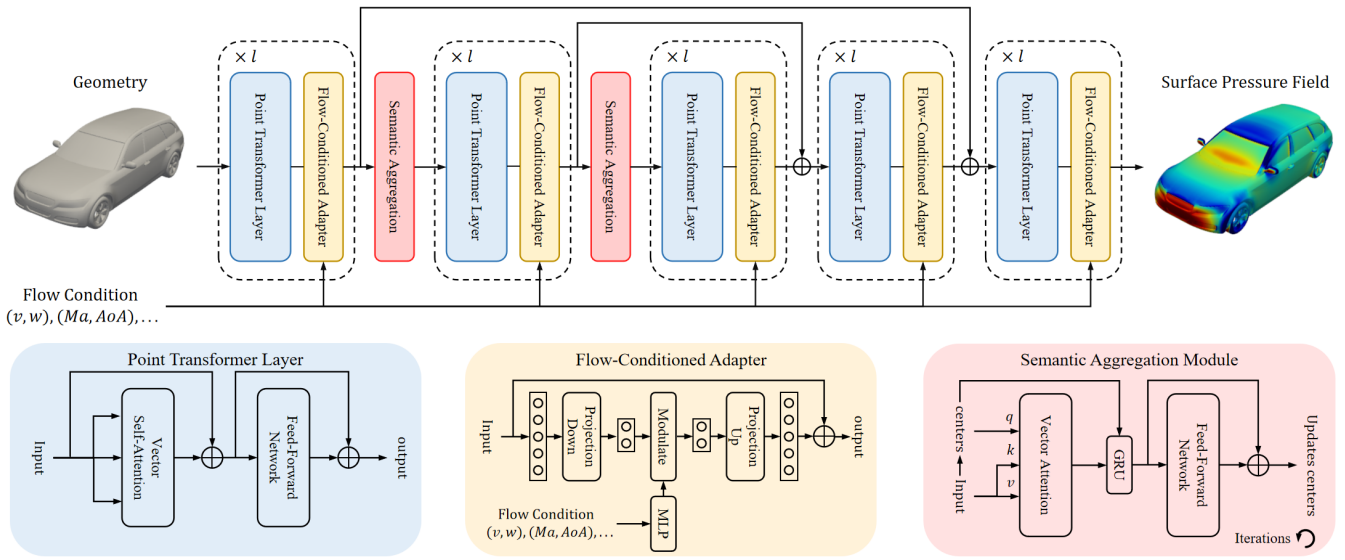


图 2：架构。输入包括以点云表示的几何形状，以及速度、马赫数和攻角等流动条件。模型通过点变换器层和流动条件适配器提取特征。整体网络结构采用 U-Net 风格，下采样过程使用语义聚合模块，在特征引导下聚合点云；上采样过程则采用 KNN 插值。

物理信息模型优化

通过物理信息约束或正则化项将物理定律纳入神经网络损失函数，可增强模型的泛化能力、提高可解释性，并确保预测结果具有物理一致性。这对于空气动力学应用尤为重要，因为传统的数据驱动模型可能违背基本的空气动力学原理。物理信息神经网络（PINNs）（Raissi、Perdikaris 和 Karniadakis，2019）是一种通过复合损失函数强制满足控制偏微分方程或守恒定律的典型方法，在场建模中十分常见（Yan 等，2024；Mao、Jagtap 和 Karniadakis，2020；Cai 等，2021）。Transolver（Wu 等，2024）提出了物理注意力，将具备物理感知能力的切片机制嵌入注意力模块，使潜在令牌与网格域中的物理状态相对齐，从而提升模型在复杂几何形状上的性能。PEINR（Shen 等，2025）通过高斯时间编码解耦时间与空间分量，增强高维特征及时间信息的非线性特征，并采用局部空间编码。近期的偏微分方程求解器（Zhou 等，2024）提出利用大语言模型表示偏微分方程符号（如系数、边界条件等），并将其作为条件输入基于 Transformer 的前向过程中，从而在多种物理情境下实现强泛化能力，提升物理感知建模能力。Wang 等（2025）提出通过交叉注意力融合纳入流动条件，并引入由流动条件（如马赫数、攻角）推导出的物理方程构造损失，以实现物理信息正则化训练。

方法

我们的网络框架 AdaField 如图 2 所示。网络输入由几何形状和流动条件组成。几何形状以点云 $G \in \mathbb{R}^{N\times 3}$ 表示，其中 N 表示表面节点的数量。流动条件编码为向量 $C \in \mathbb{R}^{D_f}$，其中 D_f 表示所考虑的流动参数数量。网络为每个表面节点预测一个标量压力系数，得到输出 $P \in \mathbb{R}^{N}$。

为对复杂的空间交互进行建模，AdaField 采用向量自注意力提取逐点几何特征，并在每个注意力块之后接入流动条件适配器（FCA），以融入特定流动的信息。我们采用 U-Net 风格的架构（Ronneberger、Fischer 和 Brox，2015）来支持稠密的逐点预测。在每个阶段，AdaField 通过向量自注意力和 FCA 提取特征后，使用语义聚合模块进行下采样。与之对称，解码器通过 K 近邻（KNN）插值逐步上采样点特征，并融入来自对应编码器层的跳跃连接特征。最后，线性输出层对恢复后的高分辨率点云进行处理，生成压力预测。

预备知识：用于点云的向量自注意力

AdaField 采用点变换器（Zhao 等人，2021）中提出的向量自注意力，以增强其从点云数据中捕捉局部几何结构的能力。每个点云 Transformer 层以一组特征及其对应的坐标作为输入，记为输入 $= (x,\ p)$，其中 $x \in \mathbb{R}^{N\times D}$ 表示点特征，$p \in \mathbb{R}^{N\times 3}$ 表示三维坐标。

点 i^{th} 的注意力输出 y_i 计算如下：

$$\begin{aligned}
&\delta_{ij} = \mathcal{P}(p_i - p_j),\\
&q_i, k_i, v_i = \mathcal{Q}(x_i), \mathcal{K}(x_i), \mathcal{V}(x_i),\\
&y_i = \sum_{x_j \in N(x_i)} \mathrm{Softmax}(\gamma(q_i - k_j + \delta_{ij})) \odot (v_j + \delta_{ij}),
\end{aligned} \tag{1}$$

其中， $\mathcal{Q}, \mathcal{K}, \mathcal{V}$ 是线性投影函数， $\mathcal{P}$ 和 γ 是两层多层感知机， $N_k(x_i)$表示点 x_i的k近邻集合。为进一步丰富表示，我们遵循标准变换器设计，采用残差连接和前馈网络（FFN）：

$$x_i \leftarrow x_i + y_i, \quad x_i \leftarrow x_i + \mathrm{FFN}(x_i). \tag{2}$$

语义聚合模块

典型的点云下采样方法使用最远点采样（FPS）（ Eldar 等，1997）选择点的子集，随后在所选点的 K 近邻（KNN）内进行特征聚合。然而，这类方法仅依赖空间邻近性，未能充分利用局部结构之间潜在的几何相似性，而我们认为这对于跨不同车辆形状的泛化至关重要。

为此，我们引入了一个语义聚合模块，该模块改编自 Slot Attention （ Locatello 等，2020 ），其最初是为目标发现而开发的（Villa-V´asquez 和 Pedersoli，2024）。不同于传统的基于距离的分组方式，语义聚合模块依据可学习的特征相似性对点进行分组，使网络能够从输入几何结构中捕获语义层面的结构。

形式化地，给定输入 input $= (x,\ p)$，其中 $x \in \mathbb{R}^{N\times D}$ 表示点特征， $p \in \mathbb{R}^{N\times 3}$ 表示坐标，我们使用最远点采样选择 K 个初始聚合中心 $S = (x_s,\ p_s)$，其中 $x_s \in \mathbb{R}^{K\times C}$ 和 $p_s \in \mathbb{R}^{K\times 3}$。随后，通过以下公式在多次迭代中更新 x_s ，以整合其他点的信息：

$$\begin{aligned}
&\delta_{ij} = \mathcal{P}_s(p_{s,i} - p_j),\\
&q_i, k_i, v_i = \mathcal{Q}_s(x_{s,i}), \mathcal{K}_s(x_i), \mathcal{V}_s(x_i),\\
&y_{s,i} = \sum_{x_j \in N_k(x_{s,i})} \mathrm{Softmax}(\gamma_s(q_i - k_j + \delta_{ij})) \odot (v_j + \delta_{ij}),\\
&x_s \leftarrow \mathrm{GRU}(x_s, y_s),\\
&x_s \leftarrow x_s + \mathrm{FFN}(x_s),
\end{aligned} \tag{3}$$

这里， $\mathcal{Q}_s, \mathcal{K}_s, \mathcal{V}s$ 是线性投影函数， $\mathcal{P}s$ 和γ_s 是两层多层感知机， $N_k(x_{s,i})$表示点集 x中槽位$x_{s,i}$ 的k近邻。

流动条件适配器

在分析表面压力时，不同类型的交通工具通常需要考虑不同的输入流动条件。例如，汽车和列车的表面压力场通常受行驶速度和侧风速度的影响（Qiu et al. 2025）。相比之下，对于飞机，流动条件通常由马赫数（Ma）和攻角（AoA）（Zhang et al. 2024）描述。这限制了模型在不同空气动力学场景中的通用性。

为解决这一问题，我们提出了流动条件适配器（FCA），它能够针对不同的流动条件独立学习表征。FCA 添加在每个向量自注意力层之后。在每个 FCA 中，首先将输入点云特征 x 投影到较低维度。然后，通过两层多层感知机，根据流动条件C 生成一组缩放因子 σ 和偏置 μ ，以调制投影后的特征。最后，将特征投影回初始维度，并通过残差连接与原始特征相加。投影通过线性层、层归一化和 GELU 激活函数实现。形式化地，

$$\begin{aligned}
&\sigma, \mu = \mathrm{MLP}(C),\\
&y = \mathcal{P}_{\mathrm{out}}((\mathcal{P}_{\mathrm{in}}(x) + \mu) \odot \sigma),\\
&x \leftarrow x + y,
\end{aligned} \tag{4}$$

其中， $\mathcal{P}_{\mathrm{in}}$ 和 $\mathcal{P}_{\mathrm{out}}$ 是由线性层、层归一化和 GELU 激活函数组成的投影。

物理信息数据增强

在不同工程领域中实现可泛化的表面压力场预测模型，一大障碍是物体尺度和速度存在显著差异。例如，典型汽车长约 5 米，行驶速度通常低于 40 m/s；而高速列车的长度可达数十米，速度接近 100 m/s。因此，对于仅使用汽车数据集训练的模型而言，高速列车数据代表着完全未见过的数据分布，给泛化带来了巨大挑战。

为解决这一问题，我们提出一种基于稳态不可压缩纳维–斯托克斯方程（Constantin and Foiaş 1988）的物理信息数据增强（PIDA）技术。该方法系统地对现有数据进行缩放和速度变换，从而拓宽有效训练分布并提升模型的适应能力。形式化地，我们提出以下定理：

定理1 设 $G \in \mathbb{R}^{N\times 3}$ 表示车辆的几何形状， $v \in \mathbb{R}$ 表示行驶速度， $C_p \in \mathbb{R}^N$ 表示无量纲表面压力系数。在稳态不可压缩流动条件下，以速度 $v' = cv$ 行驶的几何形状$G' = G/c$ 具有相同的表面压力系数 C_p。

证明见补充材料。通过改变缩放因子 c，我们可以生成与移动速度较慢的较大物体或移动速度较快的较小物体相对应的表面压力场，从而有效拓展数据分布。在实践中，我们定义一个范围$[c_{\min}, c_{\max}]$ ，并在该范围内均匀采样 c ，以扩充训练样本的尺寸和速度。

实验

在汽车空气动力学等广泛研究的领域，大规模数据集可公开获取。然而，在列车或飞机等专业领域，可获得的数据有限

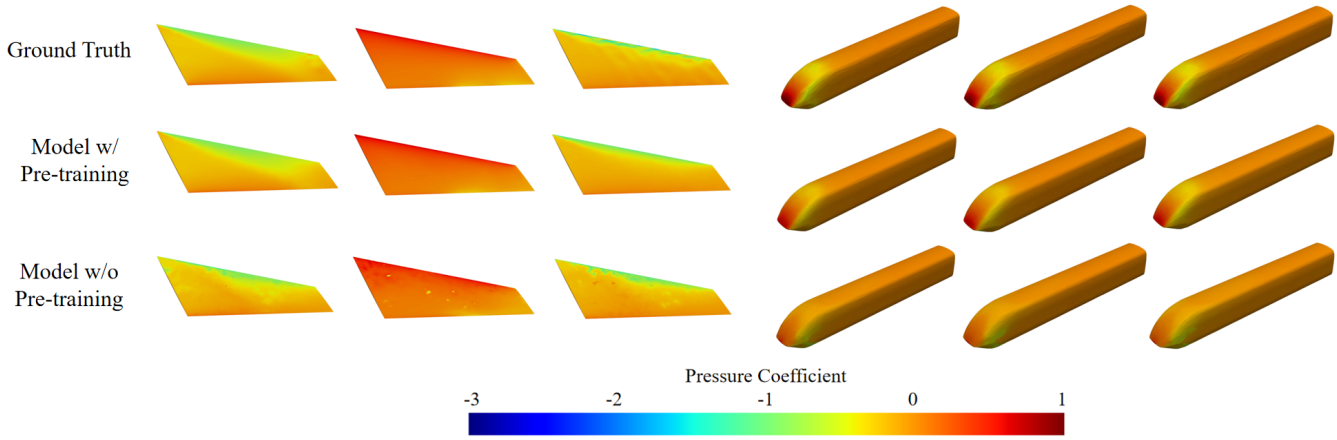


图3：用于几何泛化的预训练模型。将模型应用于磁悬浮列车和飞机机翼时，是否使用 DrivAerNet++进行预训练会带来巨大差异。在飞机机翼数据集中，预训练模型给出的结果更加自然，压力变化平滑且稳定。至于磁悬浮列车，未经预训练的模型几乎会在整个表面上给出完全均匀的分布。这表明，当某个较小领域的数据稀缺时，仅从头训练模型不足以使其对未知几何结构实现良好的泛化，而使用 DrivAerNet++进行预训练则有助于提升泛化能力。

模型	DrivAerNet++				
	↓MSE ($\times 10^{-2}$)	↓MAE ($\times 10^{-1}$)	↓最大绝对误差	↓相对 L2 (%)	↓相对 L1 误差 (%)
RegDGCNN（2024年）	8.29	1.61	10.81	27.72	26.21
Transolver（2024年）	7.15	1.41	7.12	23.87	22.57
FigConvNet（2025）	4.99	1.22	6.55	20.86	21.12
TripNet（2025）	5.14	1.25	6.35	20.05	20.93
AdaField（本文方法）	**4.58**	**1.05**	**6.22**	**19.81**	**17.28**

表1：DrivAerNet++上的模型性能比较。

这些数据可通过计算流体力学（CFD）模拟获得。数据稀缺使得从头训练一个具备泛化能力的模型颇具挑战。因此，将相关领域的预训练模型迁移到这些专业领域至关重要。

本节首先在汽车数据集 DrivAerNet++ 上针对表面压力场预测任务对 AdaField 进行预训练，并将其性能与当前最先进模型进行基准比较，以展示其性能优势。随后，我们介绍列车和飞机机翼的数据集，并仅使用有限数量的样本在这些目标领域上对 AdaField 进行微调。我们将结果与未经预训练的模型进行比较，以验证 AdaField 能够在预训练过程中有效捕获通用空气动力学知识，并能很好地泛化到新领域。

数据集

DrivAerNet++ (Elrefaie et al. 2025)：DrivAerNet++ 是一个公开的大规模高保真数据集，专为基于学习的车辆空气动力学分析而构建。所有数据均由高分辨率计算流体力学仿真生成，使用了稳态不可压缩流求解器。每个样本均记录了一辆以 30 m/s 行驶的车辆的三维表面压力场。DrivAerNet++共包含 8,000 多个样本，每个样本包含汽车模型的表面点云及其对应的压力场，且每个点云均由 500,000 多个表面点构成。这个丰富的数据集支持多种空气动力学预测任务，包括升力和阻力估算，以及表面压力和壁面剪切应力等密集参数预测。本文主要关注表面压力预测任务。

列车数据集 (Qiu et al. 2025)：该列车数据集包含一辆高速列车和两辆磁悬浮列车的几何形状，并在多种流动条件下进行了计算流体动力学模拟。具体而言，流动条件由列车的行驶速度以及垂直于行驶方向的侧向风速表征。高速列车的速度范围为 270 km/h 至 350 km/h，间隔为 10 km/h；侧向风速范围为 0 m/s 至 15 m/s，间隔为 5 m/s，共得到 36 个样本。对于每种磁悬浮列车几何形状，速度范围为 70 m/s 至 100 m/s，间隔为 10 m/s；侧向风速范围为 0 m/s 至 20 m/s，间隔为 5 m/s，每种几何形状对应 20 个样本。

飞机机翼数据集 (Wang et al. 2025)：该数据集包含 10 种飞机机翼几何结构。流动条件由马赫数和攻角描述。对于每种几何结构，马赫数范围为 0.2 至 0.8，间隔为 0.2；攻角范围为 –15° 至 15°，间隔为 5°，每种几何结构对应 28 个样本。

指标

我们采用 DrivAerNet++排行榜使用的评估指标，全面评估模型性能。这些指标包括均方误差（MSE）、平均绝对误差（MAE）、最大绝对误差（MaxAE）、相对L2误差（RelL2）和相对 L1 误差

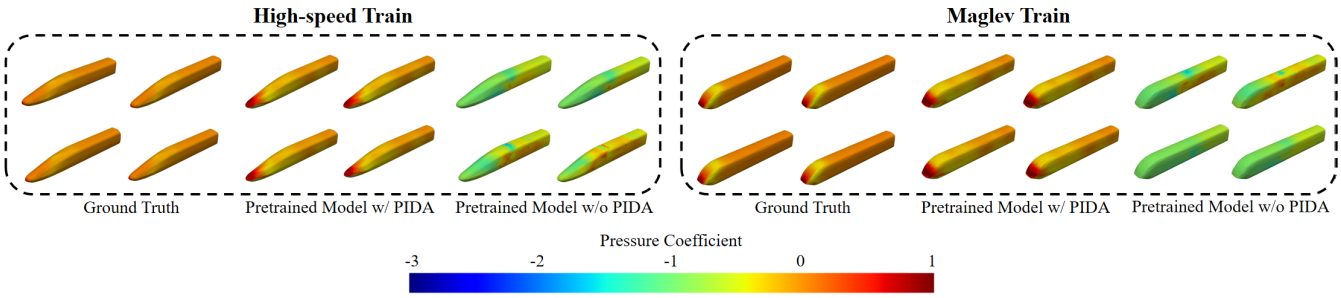


图4：将预训练模型直接应用于列车训练场景，**不进行微调**。采用 PIDA 的模型预测出的压力分布与真实值高度吻合。相比之下，不采用 PIDA 的模型在整个表面上都预测出负压，甚至包括前部，这凸显了其缺乏物理一致性。

数据集	预训练	↓MSE ($\times 10^{-2}$)	↓MAE ($\times 10^{-1}$)
机翼		16.63	2.18
	✓	**11.46**	**1.52**
列车		1.79	0.51
	✓	**0.99**	**0.38**

表2：微调模型与从头训练模型的比较。尽管列车和机翼场景与汽车差异很大，但在 DrivAerNet++ 上进行预训练后，误差仍显著降低。

（相对 L1 误差）。**数值越低越好**，所有指标均如此。

DrivAerNet++ 基准比较

设置：遵循先前的研究（Choy 等，2025；Chen 等，2025），我们从完整点云中随机抽取 32,768 个点，分别用于训练和测试。训练集与测试集的划分遵循 DrivAerNet++GitHub 仓库提供的官方划分。所有压力值均通过减去均值（-94.5）并除以标准差（117.25）进行归一化。

流动条件包括行驶速度 v 和侧风速度 w。由于 DrivAerNet++ 未模拟侧风，w 固定为零，但为与后续列车数据集保持一致而予以保留。我们使用 PIDA 扩展行驶速度和汽车尺度范围。具体而言，c_{min}和 c_{max} 设为 0.2 和 3.2，将速度范围扩展至 6–96 m/s，车辆尺寸范围扩展至 1.5–25 m。测试时不进行数据增强，而是使用原始数据。

结果：结果汇总于表1。AdaField始终优于所有基线方法。具体而言，其均方误差（MSE）最低，为4.58 $\times 10^{-2}$，相比此前表现最佳的FigConvNet（4.99）提升了约10%。在平均绝对误差（MAE）方面，AdaField达到1.05 $\times 10^{-1}$，比排名第二的竞争方法低逾15%。此外，其最大绝对误差（最大AE）也达到最佳，表明其抵御离群值的鲁棒性有所提升。这些结果确立了AdaField在表面压力预测领域的最先进水平。

泛化至新领域

设置：我们对在DrivAer-Net++ 上预训练的模型进行微调，并使用有限数据将其迁移至包括列车数据集和飞机机翼数据集在内的新领域。在微调过程中，仅更新流动条件适配器（FCA）的参数。对于列车数据集，模型在高速列车和一种磁悬浮列车几何结构上进行训练，并在另一种磁悬浮列车上进行测试。对于飞机机翼数据集，模型使用来自五种机翼几何结构的数据进行训练，并在剩余五种几何结构上进行测试。为验证预训练的优势，我们将该微调模型与从头开始训练的模型进行比较，后者的所有参数均使用目标数据进行训练。

结果： 如表2所示，微调后的模型显著优于从头开始训练的模型，在两个数据集上的预测误差均降低了约三分之一。对于列车数据集，图3中的可视化结果突显了这一差异：对于磁悬浮列车，表面压力通常在车头处为正值，在车头与车身的连接处为负值，而在车身其余部分则接近于零。微调后的模型给出了相似的压力分布，而从头开始训练的模型预测的压力分布则未能反映列车车头处剧烈的压力变化。对于飞机机翼数据集，微调后的模型也大幅降低了预测误差。如图3所示，微调后的模型的预测结果与真实值更加一致，而未微调模型的预测结果则不稳定，且出现了异常斑块。这些结果表明，尽管预训练数据与目标数据之间存在显著差异，AdaField仍能成功捕获可迁移的空气动力学知识，并仅凭少量目标领域数据实现有效泛化。

消融研究与分析

本研究通过在模型和数据两方面进行多项改进，解决表面压力场预测中数据有限的挑战。这些改进包括：SAPT，融合语义聚合模块与向量自注意力，以增强特征表示；FCA，使模型能够适应未见过的流动条件，并实现参数高效微调；以及 PIDA，扩充训练数据，以提升对未见数据的泛化能力。本文开展了消融研究

数据集	SAPT	PIDA	↓MSE ($\times 10^{-2}$)	↓MAE ($\times 10^{-1}$)
DrivAerNet++		✓	5.22	1.14
	✓	✓	**4.58**	**1.05**
机翼		✓	13.05	1.79
	✓		12.95	1.91
	✓	✓	**11.46**	**1.52**
列车		✓	1.15	0.44
	✓		1.35	0.61
	✓	✓	**0.99**	**0.38**

表3：消融研究。我们考察 SAPT、PIDA，并在每一行中消融一个组件，以展示各组件对最终性能的贡献。

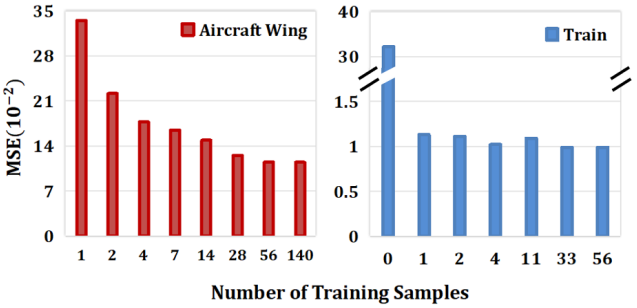


图5：减少微调样本数量时模型的性能趋势。

和分析，以验证各个组成部分的贡献。

语义聚合模块语义聚合模块取代了点云处理中常用的 FPS +K近邻下采样策略。对比结果如表3所示，SAPT 栏未打勾的模型采用传统的 FPS + K近邻下采样。对于所有数据集，加入语义聚合模块都能显著提升性能，使所有数据集的误差降低约 10% 至 20%。

物理信息数据增强PIDA 使 AdaField 能够在更广泛的速度和缩放因子范围内实现泛化，从而提升其在未见场景中的鲁棒性和适应性。如图4所示，我们展示了直接应用于列车数据集**且未经微调**时，采用和未采用 PIDA 的模型所预测的表面压力场。采用 PIDA 的模型生成的表面压力分布与真实值高度相似，捕捉到了关键的物理模式，例如前部的正压、过渡区域的负压，以及主体沿线近乎为零的压力。相比之下，未采用 PIDA 的模型无法预测符合物理常识的压力分布，例如预测列车前部为负压。

这些结果直观地凸显了 PIDA 在学习具有物理一致性且可迁移的知识方面的有效性，使模型能够泛化到新的交通运输系统。这也为模型在微调后取得更优性能奠定了基础。如表3所示，与未采用 PIDA 的模型相比，采用 PIDA 的模型在微调后，机翼上的误差降低了约 15%，列车上的误差降低了约三分之一。

流动条件适配器除了使模型适应不同的流动条件外，FCA 还使模型能够进行参数高效微调，从而实现少样本迁移学习。为验证模型利用样本的效率，我们进一步减少训练所用的数据量，并验证仅用一个样本进行微调这一最极端的情形。

图5展示了使用不同数量样本时的详细性能趋势。对于列车数据集，尽管数据量减少，模型的性能并未显著下降。即使只使用一个样本，也能将误差降至相对较低的水平，这可能与不同列车数据之间的压力分布相似有关。对于飞机机翼数据，由于攻角的影响，不同样本之间的压力分布差异显著，因此需要更多数据进行微调。尽管如此，使用约28个样本（占全部样本的20%）时，模型的预测误差仍可接近使用全部140个样本训练的模型。

结论

表面压力场在塑造能够降低能耗并提升运行稳定性的设计方面发挥着至关重要的作用。神经网络已成为传统计算密集型方法（如计算流体力学仿真）在表面压力预测方面的有效替代方案。然而，流体动力学的许多子领域都面临高保真度数据匮乏的问题，这限制了数据驱动方法的广泛应用。

我们致力于解决如何在公开的大规模数据集上对模型进行预训练，并将其迁移到数据稀缺的专门领域这一问题。在本文中，我们通过设计 AdaField 验证了这一方法。AdaField 是一个集成了语义聚合点变换器（SAPT）、流动条件适配器（FCA）和物理信息数据增强（PIDA）的框架：SAPT 是一种用于处理点云的高性能网络；FCA 通过参数高效微调，使模型能够适应不同的流动条件；PIDA 则用于扩展数据分布并增强泛化能力。

我们的实验表明，所提出的组件不仅在公开的 DrivAerNet++ 数据集上达到了最先进水平，还能有效迁移至飞机和列车领域，与从头训练相比，误差显著降低。我们的研究结果凸显了神经网络在不同领域统一流场表征的潜力，使其能够充当通用的表面压力预测模型，为各种交通运输系统的气动优化提供支持。

致谢

本研究得到国家重点研发计划（编号：2025ZD0122000）、中国科学院战略性先导科技专项（项目编号：XDA0480103）、国家自然科学基金（92570119）以及中国国家铁路集团科技计划（项目编号：N2024J040）的资助。

本文在雷震教授的指导下完成。

参考文献

Ashton, M.-C. F. M. F. L. H. H. K. T. S. N. S. V. F. G. W. A. H. B., N.; and Maddix, D. 2024年. DrivAerML：面向道路汽车外部空气动力学的高保真计算流体力学数据集。*arxiv.org*。Ashton, N.; Angel, J.; Ghate, A.; Kenway, G.; Long Wong, M.; Kiris, C.; Walle, A.; Maddix, D.; and Page, G. 2024a. WindsorML：面向汽车空气动力学的高保真计算流体力学数据集。神经信息处理系统进展 *37*。Ashton, N.; Maddix, D.; Gundry, S.; and Shabestari, P. 2024b. AhmedML：面向不可压缩低速钝体空气动力学的高保真计算流体力学数据集。*arxiv.org*。Cai, S.; Wang, Z.; Wang, S.; Perdikaris, P.; and Karniadakis, G. E. 2021年. 用于传热问题的物理信息神经网络。传热学杂志，143(6)：060801。Chen, Q.; Elrefaie, M.; Dai, A.; and Ahmed, F. 2025. Trip-Net：利用三平面网络学习大规模高保真三维汽车空气动力学。arXiv:2503.17400。Choy, C.; Kamenev, A.; Kossaifi, J.; Rietmann, M.; Kautz, J.; and Azizzadenesheli, K. 2025. 面向汽车计算流体力学预测的因子化隐式全局卷积。arXiv:2502.04317。Co nstantin, P.; and Foias., C. 1988. 纳维–斯托克斯方程。芝加哥大学出版社。Eldar, Y.; Lindenbaum, M.; Porat, M.; and Zeevi, Y. 1997. 用于渐进式图像采样的最远点策略。*IEEE*图像处理汇刊，6(9)：1305–1315。Elrefaie, M.; Dai, A.; and Ahmed, F. 2024年. Drivaernet：用于数据驱动空气动力学设计和基于图的阻力预测的参数化汽车数据集。载于国际设计工程技术会议和计算机与信息工程会议，第88360卷，V03AT03A019。美国机械工程师学会。Elrefaie, M.; Dai, A.; and Ahmed, F. 2025. DrivAerNet：用于数据驱动空气动力学设计与预测的参数化汽车数据集。机械设计杂志，147(4)。Elrefaie, M.; Morar, F.; Dai, A.; and Ahmed, F. 2025. DrivAerNet++：包含计算流体力学仿真和深度学习基准的大规模多模态汽车数据集。arXiv:2406.09624。Gao, H.; Liu, T.; Chen, X.; Huo, X.; Chen, Z.; Zhang, J.; and Khoo, B. C. 2025. 一种关于移动列车风谱的准确高效方法：复杂地形中风特性的现场测量。随机环境研究与风险评估，1–31. Houlsby, N.; Giurgiu, A.; Jastrzebski, S.; Morrone, B.; De Laroussilhe, Q.; Gesmundo, A.; Attariyan, M.; and Gelly, S. 2019. 面向自然语言处理的参数高效迁移学习。载于国际机器学习大会，2790–2799。机器学习研究论文集。Locatello, F.; Weissenborn, D.; Unterthiner, T.; Mahendran, A.; Heigold, G.; Uszkoreit, J.; Dosovitskiy, A.; and Kipf, T. 2020. 基于 Slot Attention 的以对象为中心的学习。神经信息处理系统进展，33：11525–11538。Luo, H.; Wu, H.; Zhou, H.; Xing, L.; Di, Y.; Wang, J.; and Long, M. 2025. Transolver++：一种用于百万尺度几何体上偏微分方程的高精度神经求解器。arXiv:2502.02414。Mao, Z.; Jagtap, A. D.; and Karniadakis, G. E. 2020. 面向高速流动的物理信息神经网络。计算机辅助力学与工程方法，360：112789。Qiu, W.; Sun, Z.; Wang, J.; Bai, Y.; Yao, S.; Guo, D.; and Yang, G. 2025. 一种基于压缩感知、从稀疏测量重建表面压力场的框架。流体物理学，37(4)。Raissi, M.; Perdikaris, P.; and Karniadakis, G. 2019. 物理信息神经网络：一种用于求解涉及非线性偏微分方程的正问题与逆问题的深度学习框架。计算物理学杂志，378：686–707。Ronneberger, O.; Fischer, P.; and Brox, T. 2015. U-Net：用于生物医学图像分割的卷积网络。arXiv:1505.04597。Shen, L.; Deng, L.; Bi, C.; Wang, Y.; Chen, X.; Wang, Y.; and Liu, J. 2025. PEINR：一种用于高保真流场重建的物理增强隐式神经表示。载于第四十二届国际机器学习大会。Villa-V´ asquez, J.-F.; and Pedersoli, M. 2024. 无监督对象发现：综合综述与统一分类体系。arXiv:2411.00868。Wang, Y.; Zhang, P.; Liu, Y.; Zhao, J.; Lin, J.; and Chen, Y. 2025. 基于交叉注意力融合与物理信息训练的气动系数预测。人工智能促进会年会论文集，39(1)：869–876。Wu, H.; Luo, H.; Wang, H.; Wang, J.; and Long, M. 2024. Transolver：一种适用于一般几何体上偏微分方程的快速变换器求解器。arXiv:2402.02366。Yan, C.; Xu, S.; Sun, Z.; Lutz, T.; Guo, D.; and Yang, G. 2024. 一种利用物理信息神经网络进行风流场数据同化的框架。应用能源，371：123719。Zhang, Q.; Zhao, X.; Li, K.; Tang, X.; Wu, J.; and Zhang, W. 2024. 飞机铰链力矩预测模型：基于正交分解的压缩感知。流体物理学，36(7)。

Zhao, H.; Jiang, L.; Jia, J.; Torr, P.; and Koltun, V. 2021年。PointTransformer。arXiv:2012.09164。Zhou, H.; Ma, Y.; Wu, H.; Wang, H.; and Long, M. 2024年。Unisolver：偏微分方程条件变换器是通用偏微分方程求解器。arXiv:2405.17527。