arXiv:2611.28435v1 [cs.CE] 21 Nov 2026

用于汽车空气动力学代理模型的迁移学习与经验回放

Riddhiman Raut、Mehdi Bor、Katie Guo、Saakaar Bhatnagar 和 Yin Yu
Luminary，美国加利福尼亚州圣马特奥

摘要

神经代理模型能够快速预测汽车空气动力学场，但要实现高精度，通常需要大量计算流体力学数据集。为每个新的车辆项目生成这些数据集，或扩展设计空间，可能需要长期开展仿真工作。只要能够使模型适应陌生几何形状并保持预测精度，重复利用现有仿真中的知识便可以减轻这一负担。本研究使用无网格神经代理模型，在两项相互独立的汽车空气动力学实验中评估了迁移学习和经验回放。首先，模型在 SHIFT-SUV 的 1,981 个运动型多用途汽车案例上进行预训练，然后在 SHIFT-Truck 皮卡数据集的子集上进行微调。在表面配置以及表面与体积联合配置下，将目标训练集规模设为 100 至 613 个案例，以评估数据效率。与在相同目标预算下从头训练相比，微调降低了所有报告的场变量平均绝对误差（MAE）。对于表面与体积联合预测，在 100 个卡车案例上进行微调，其四项场变量平均绝对误差均达到或优于使用 200 个案例从头训练所得的结果。其次，一个独立训练的模型使用 332 个 DrivAerML 案例学习基础任务，并使用 31 个案例适应一个具有此前未见设计特征组合的新任务。在适应过程中，经验回放纳入了基础任务训练集中的案例。与不使用回放的适应相比，完全回放使 45 个留出的基础任务设计上的场变量误差降低了约 36% 至 42%；保留一半基础任务训练集则使误差降低了约 30% 至 35%。总体而言，这些发现表明，在连续的工程任务中，迁移学习和经验回放是推动数据高效神经代理模型开发的互补策略。

关键词： 汽车空气动力学；计算流体力学；LSMART；代理模型建模；迁移学习；持续学习；经验回放；数据效率

1 引言

空气动力学效率是汽车设计的核心目标，因为它直接影响汽油车的燃油消耗和电动汽车的续驶里程。即使是小幅降低
阻力可带来切实的效益：梅赛德斯-奔驰估计，阻力系数降低 0.01（相当于减少十个阻力计数），可使电动汽车的长途续驶里程增加约 2.5%[1]。要发现这类改进，就需要反复评估候选几何形状，因此车辆开发过程中亟需快速进行空气动力学评估。近年来，神经代理模型在快速预测汽车空气动力学场方面展现出良好前景，使更多

候选设计得以评估 [2, 3, 4]。公开的计算流体力学（CFD）数据集也扩充了可用于训练和基准测试这些模型的资源 [5, 6, 7, 8]。然而，模型的准确性取决于数据能否代表目标应用所涉及的几何形状和流动条件。生成这些 CFD 数据集需要对大量设计进行几何预处理、网格生成、数值求解和质量控制。由此产生的仿真工作可能耗费大量时间和计算资源；即使推理速度很快，这也会成为部署代理模型的障碍。因此，减少实现实用预测精度所需的新仿真数据量，是让神经代理模型适用于迭代式汽车设计的关键挑战。

随着车辆项目不断演进，并引入超出现有代理模型训练集所涵盖范围的几何形状，生成训练数据的问题可能会愈发突出。某一车型系列的大型计算流体力学（CFD）档案，对另一车型系列或同一系列中的新几何变体可能覆盖有限。例如，车顶线、前饰板或侧后视镜的变化可能改变周围流场，并使基于先前设计训练的模型难以保持预测精度。为每种应用生成大量新数据集，会反复占用仿真资源。重用从先前仿真中学习到的空气动力学关系，有望减少额外的数据需求，因此，让现有模型适应陌生几何形状，是实现更高数据效率的代理模型开发过程中的重要一步。

为此，迁移学习提供了一个通用框架，用于将先前获得的知识应用于相关学习问题 [9]。对于神经代理模型，一种实现方式是全量微调：以预训练权重初始化目标模型，并使用目标数据更新所有参数。Keum 和 Warey 使用 20 个目标车型系列案例研究了跨车型系列迁移，评估了表面场和力，发现低秩适配在他们的实验设置中优于全量微调 [10]。这些发现促使我们考察不同目标数据量下的全量微调，包括表面和体积的联合预测，以及表面场的改善是否也能降低阻力误差。然而，使用新数据进行微调可能会降低模型对先前已学习设计的准确性，这种现象称为遗忘 [11, 12]。因此，当模型需要适用于不断扩大的设计空间时，保持先前的预测能力也成为一项额外要求。

持续学习通过在保留先前获取的知识的同时纳入新信息，来满足这一需求 [11, 12]。经验回放是一种策略：保留从早期训练数据中选取的样本，并在后续模型更新时将其与新数据结合 [12]。Samuel 和 Ahmed 对工程回归领域的持续学习进行了基准评估，其中包括汽车空气动力学 [13]。然而，他们的汽车基准评估侧重于阻力系数预测，并未评估空间分布的表面场或体场。因此，有必要进一步研究回放记忆库大小和样本选择如何影响模型适应新几何形状后对早期设计的表面场和体场预测精度。

为回答这些问题，本研究在两项相互独立的汽车空气动力学实验中使用了无网格神经代理模型 LSMART [14], 。在第一项实验中，我们将在运动型多用途汽车（SUV）上预训练的模型在皮卡上进行微调，并在不同目标数据预算下与从头训练的模型进行比较，使用的数据集为 SHIFT-SUV 和 SHIFT-Truck [15, 16]。评估了仅预测表面以及联合预测表面和体积两种方案。仅预测表面的评估还考察了场预测的改进是否能转化为更低的阻力系数误差。第二项实验则将一个独立训练的模型从 DrivAerML 中的基础任务迁移到新任务，并在不同回放记忆库大小和案例选择策略下，评估其在留出的基础任务设计上的场精度

策略 [5]。综合来看，这些实验考察了随着车辆设计不断演变，预训练模型和保留的 CFD 案例如何提升现有仿真数据的价值。

第 2 节介绍研究方法。第 3 节展示迁移学习和经验回放的结果。第 4 节讨论这些结果对气动代理模型开发的意义。第 5 节总结研究发现，并确定未来工作的方向。

2 研究方法

2.1 神经代理模型

LSMART 是一种无网格神经代理模型 [14], ，基于 SMART编码器–解码器架构 [17]。编码器根据包含法向量和有符号距离信息的表面点云，构建车辆几何形状的紧凑表示。编码器使用表面点的粗略子集进行初始化。在每一层中，交叉注意力从输入点云中收集信息，多层感知机则对所得特征进行细化。每个解码器层都利用对应编码器层的几何特征。最终的解码器层将这些特征映射到所请求位置处的场值。

迁移实验采用了两种配置。仅表面模型预测车辆表面上的压力和壁面剪切应力。表面和体积联合模型还预测周围流场中的压力和速度。每种配置都包含约 1250 万个可训练参数。持续学习实验采用了联合配置。

2.2 数据集与数据准备

两种模型配置均使用1,981个全尺寸SHIFT-SUV案例进行了预训练。皮卡训练集和评估集取自由712个SHIFT-Truck案例组成的数据池，其中包括货箱敞开和加盖的皮卡。SUV和卡车案例分别采用延迟分离涡模拟（DDES），在固定来流速度108 km/h和140 km/h下生成。车辆几何形状和CFD设置详见SHIFT出版物 [16, 18]。

仅表面实验采用约90%/10%的训练集/测试集划分，最大数据量下包含613个训练案例。较小的100、200、300和434个案例数据集均为该训练池的子集，且各数据量下测试集保持不变。表面和体积联合实验采用约80%/10%/10%的训练集/验证集/测试集划分，最大数据量下包含550个训练案例。其100、200和300个案例数据集均为训练池的子集，而验证集和测试集保持不变。在每种数据量下，微调和从头训练均使用相同的训练案例及评估划分。在评估案例固定的情况下改变训练集规模，可以检验数据效率，同时避免因评估几何形状变化而混淆比较结果。

持续学习实验使用了 484 个 DrivAerML 案例 [5]。在数据集的参数空间中，新任务包含 41 个同时满足以下三个条件的案例：后窗倾角至少为 69.1、后扩散器角度至少为 7.6，且车辆离地高度不超过 -6.3。其余 443 个案例构成基础任务。基础任务的完整划分中，有案例分别满足每个条件，也有案例满足任意两个条件，但没有案例同时满足全部

表1： DrivAerML 重放实验的数据划分。验证集案例用于选择检查点；四个新测试案例与该选择样本群体相互独立。

Task	训练集	验证集	Test	总计
Base	332	66	45	443
新颖	31	6	4	41
总计	363	72	49	484

表2： 两项卡车迁移实验中的目标训练预算和报告量 .

模型	训练案例	报告量
仅表面	100，200，300，434，613	表面压力、壁面剪切应力和阻力
表面和体积	100, 200, 300, 550	表面压力和壁面剪切应力，以及体积压力和速度

三个条件。因此，该划分检验了模型在单一乘用车系列中对设计特征新组合的适应能力。

基础任务包含332个训练案例、66个验证集案例和45个留出测试案例；新任务包含31个训练案例、6个验证集案例和4个留出测试案例（表1）。在所有重放比较中，这些划分均保持固定。验证集和测试案例均未纳入回放记忆。

训练和评估期间，每个计算流体力学案例均由随机采样的点表示。卡车案例使用约16,000个表面点；在联合配置下，还使用80,000个体积点。DrivAerML案例使用约16,000个表面点和32,000个体积点。

对于SUV到卡车迁移，在微调和推理期间保留了根据源数据计算的输入与输出归一化统计量。

2.3 迁移学习流程

全量微调与从头训练使用表2中各预算对应的相同卡车训练样本进行比较。两个配置分别由不同的SUV预训练检查点初始化：仅表面卡车模型由仅表面检查点微调而来，表面与体积联合卡车模型则由组合检查点微调而来。两个检查点均使用相同的1,981个SHIFT-SUV案例进行预训练。微调期间更新了所有参数。每种配置的基线模型均从随机初始化开始训练。图1展示了迁移流程。

SUV预训练和卡车训练使用Lion优化器 [19]，以最小化相对 L_2 场损失。SUV预训练和从头训练卡车的初始学习率为 1×10^{-5}。微调的初始学习率为 5×10^{-5}。表3总结了训练设置。

对于每次仅使用表面数据的卡车训练，均保留训练损失最低的检查点。对于联合使用表面和体积数据的训练，检查点选择依据是独立验证集上的最低损失。在这两种配置下，均使用留出测试案例对选定模型进行了评估。

表3： 迁移学习和持续学习的训练设置。采样数量约为 e.

设置	值
模型规模	约 1250 万个可训练参数
优化器	Lion，β值为 0.9 和 0.99，权重衰减为 0
初始学习率	1×10^{-5} 用于 SUV预训练、从头训练和重放阶段1。 5×10^{-5} 用于微调和重放阶段2。
调度	500 个训练轮数，采用每轮更新的余弦学习率调度，并最终降至零。禁用预热和早停。
批次和精度	每批次一个案例，单精度浮点数
梯度裁剪	范数上限为 10，数值上限为 10
卡车采样	联合模型使用 16,000 个表面点和 80,000 个体积点
DrivAerML采样	16,000 个表面点和 32,000 个体积点
训练损失	SUV预训练和卡车训练的相对 L_2 。DrivAerML 的平均绝对误差。
检查点选择	SUV预训练和联合卡车运行的最低验证集损失。仅表面卡车运行的最低训练集损失。相应 重放阶段的最低验证集损失。
卡车训练硬件	八个GPU

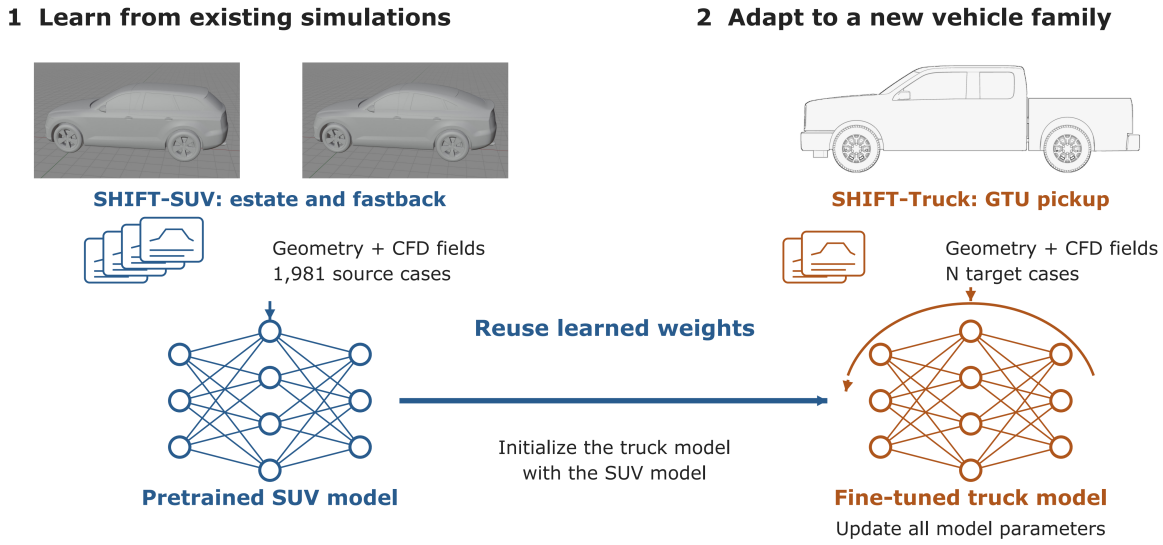

图1： 卡车LSMART模型使用SUV预训练权重进行初始化，然后在卡车CFD数据上进行微调。基线模型在相同的目标预算下从随机初始化开始训练（表2）。模型符号仅用于概念性示意。SUV图像来自Emory等人。[18], 图1。AeroSUV几何形状来自斯图加特汽车工程与动力系统研究所（FKFS），图像来自Luminary。卡车轮廓改编自Raut等人。[16], 图1a，并依据CC BY 4.0移除了参数标注。车辆视图以不同的比例显示。

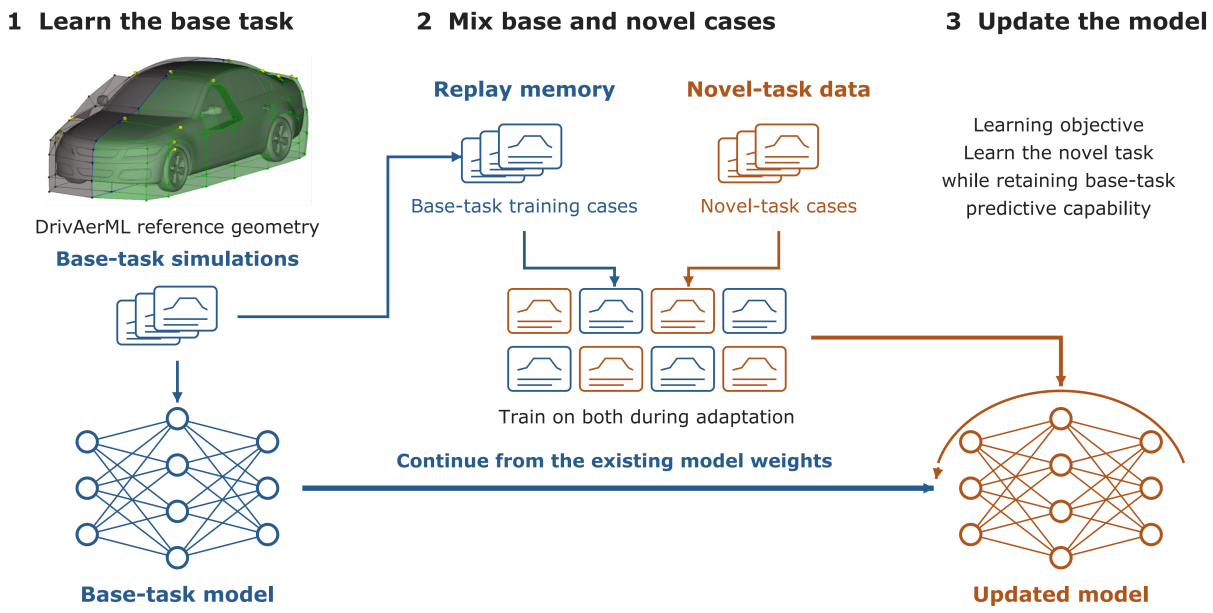

图2： 用于持续适应的两阶段训练流程。LSMART首先在基础任务设计上进行训练。随后，将所得检查点在新任务案例上进行微调，同时通过回放从基础任务训练集中保留的案例中抽取数据。模型符号和卡片数量仅为概念性表示。示例 DrivAerML 几何结构来自 Ashton等人 [5], 图2a，依据 CC BY 4.0 发布。

2.4 持续学习流程

在阶段 1 中，LSMART 从随机初始化开始，以 1×10^{-5} 的初始学习率在 332 个基础任务训练案例上进行训练。在 66 个基础任务验证案例上损失最低的检查点，被用于初始化每次阶段 2 的运行。

在阶段 2 中，每次运行均使用相同的 31 个新训练案例。根据表4中的回放记忆库大小加入基础任务训练案例，而无回放基线仅使用新任务案例。所有模型参数均以 5×10^{-5} 的初始学习率进行更新。两个阶段均采用 MAE损失和表3中的训练设置。两个阶段的每次运行均使用两块 NVIDIA H100 GPU。图2展示了该流程。

对于随机回放，基础任务训练案例均匀且不放回地抽取，以形成单一排序。对于潜在多样性回放，通过最远点采样 [20] 使用预训练Point-MAE编码器的768维几何嵌入[21]构建排序。嵌入仅计算一次，之后保持不变。在每个步骤中，将与最近已选案例之间欧几里得距离最大的案例加入。每个记忆集均由其排序的起始部分构成，因此，较大的记忆集保留了在较小规模下选中的案例。在完全回放时，两种策略均使用全部332个基础任务训练案例，并共享同一个结果。

每次阶段 2 运行均遵循 500轮训练计划，并保留验证损失最低的检查点。每个验证集均包含相同的六个新任务案例，以及表 4 中规定数量的基础任务设计案例。对于每种配置，基础任务设计的性能均在相同的 45 个留出测试案例上进行评估。

表 4： 阶段 2 数据集组成与计划病例呈现次数。回放记忆以 332 个基础任务训练案例的百分比表示。每种设置均包含 31 个新训练案例和 6 个新验证病例。病例呈现次数按训练案例总数乘以 500 个训练轮数计算。

回放记忆 (%)	基础训练病例	训练案例总数病例	Case 演示文稿	基础/总计验证病例
0	0	31	15,500	0 / 6
10	33	64	32,000	7 / 13
25	83	114	57,000	17 / 23
50	166	197	98,500	33 / 39
75	249	280	140,000	50 / 56
100	332	363	181,500	66 / 72

2.5 评估指标

与参考计算流体力学解的一致性使用公式 (1) 中定义的平均绝对误差（MAE）进行量化。对于每个输出通道 q，先对每个案例中采样点的绝对误差取平均，再对 N 评估案例取平均，使每个车辆案例具有相同权重。

$$\mathrm{MAE}_q = \frac{1}{N}\sum_{i=1}^{N}\frac{1}{n_i}\sum_{j=1}^{n_i}\left|\widehat{q}_{ij} - q_{ij}\right|. \tag{1}$$

其中，q_{ij} 和 $\widehat{q}_{ij}$ 分别是案例 i中点 j 处的参考值和预测值，n_i 是该案例中的采样点数。报告的壁面剪切应力平均绝对误差是x、y和z分量平均绝对误差的平均值。压力和壁面剪切应力误差以帕斯卡为单位报告，速度误差以米每秒为单位报告。

对于仅表面卡车配置，将预测的压力和壁面剪切载荷在车辆表面上积分，以获得阻力。阻力系数平均绝对误差使用公式 (2) 计算

$$\mathrm{MAE}_{C_D} = \frac{1}{N}\sum_{i=1}^{N}\left|\widehat{C}_{D,i} - C_{D,i}\right|, \tag{2}$$

其中，$\widehat{C}_{D,\,i}$ 和$C_{D,\,i}$ 分别是案例 i 的预测阻力系数和参考阻力系数。图3中的一个绘图计数对应于 10^{-3} 中的 C_D。

相对于参考模型的平均绝对误差相对变化量使用公式（3）计算

$$\Delta E\ (\%) = 100 \times \frac{E_{\mathrm{method}} - E_{\mathrm{ref}}}{E_{\mathrm{ref}}}, \tag{3}$$

其中，E_{method} 和 E_{ref} 分别表示评估模型及其参考模型的平均绝对误差。参考模型针对卡车迁移从头训练，并在持续学习过程中不使用回放进行适配。ΔE 为负值表示误差降低。在每种模型配置内比较不同卡车训练预算。回放比较中的所有配置均在相同的45个留出的基础任务设计上进行评估。

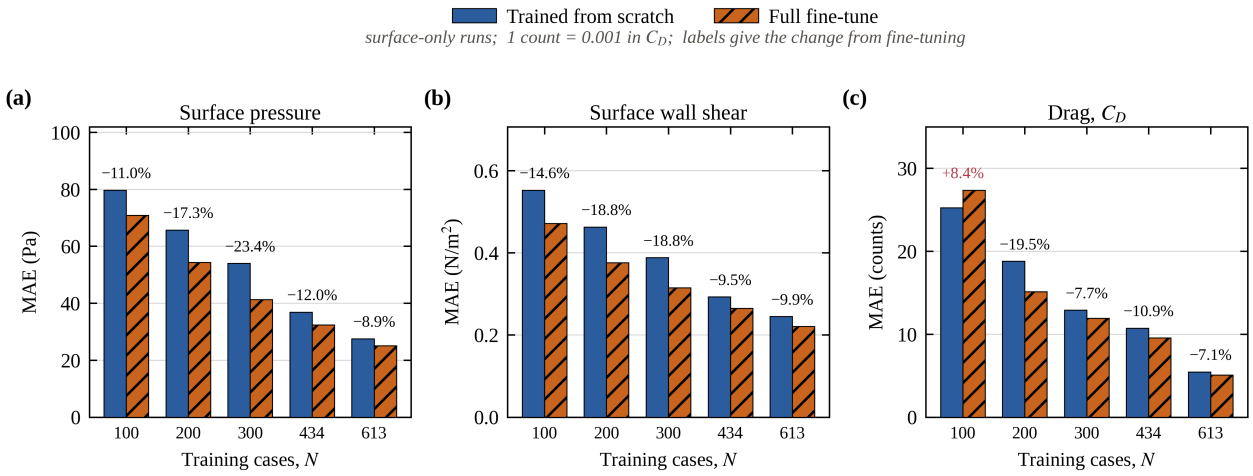

图3： 仅表面卡车模型的表面压力、壁面剪切应力和阻力系数平均绝对误差。百分比变化均相对于相同预算下从头训练的结果。图中绘制的每个阻力计数对应于 10^{-3} in C_D。

3 结果

3.1 仅表面迁移与阻力预测

在每个测试的卡车训练预算下，对SUV预训练模型进行微调均改善了两种表面场（图3）。与从头训练相比，压力的平均绝对误差降低了8.9%至23.4%，壁面剪切应力的平均绝对误差降低了9.5%至18.8%。对于这两种训练方法，随着加入更多卡车案例，场误差的绝对值均有所降低。最大预算下微调带来的相对优势小于中等预算下的优势，但并未呈单调下降趋势。随着可用目标数据增多，对源任务信息的依赖减弱，这一规律与此相符。

在四个较大预算下，这种改进也扩展到了阻力预测，其中阻力系数平均绝对误差降低了7.1%至19.5%。例如，在200个样本下，误差从约0.0188降至0.0151。100个样本的比较结果则是例外：尽管两个表面场的误差均有所降低，阻力系数平均绝对误差却增加了8.4%。较低的平均场变量误差不一定会带来较低的阻力误差，因为阻力积分取决于压力和剪切贡献的空间加权及带符号抵消。

3.2 迁移学习用于表面和体积联合预测

当同时预测表面场与体积场时，微调的优势扩展到了周围流场。在每个测试预算下，四个场变量平均绝对误差均低于相应的从头训练模型（图4）。最大降幅出现在100个样本时，此时体积压力和速度的平均绝对误差分别降低了29%和31%。在550个样本时，四个场变量的误差均降低了9%至11%。

不同数据预算下的比较表明，现有的运动型多用途汽车检查点可以减少对新卡车模拟的需求。使用100个卡车案例进行微调，其四个场变量平均绝对误差均达到或优于使用200个案例从头训练所得的结果。同样，使用200个案例进行微调可获得

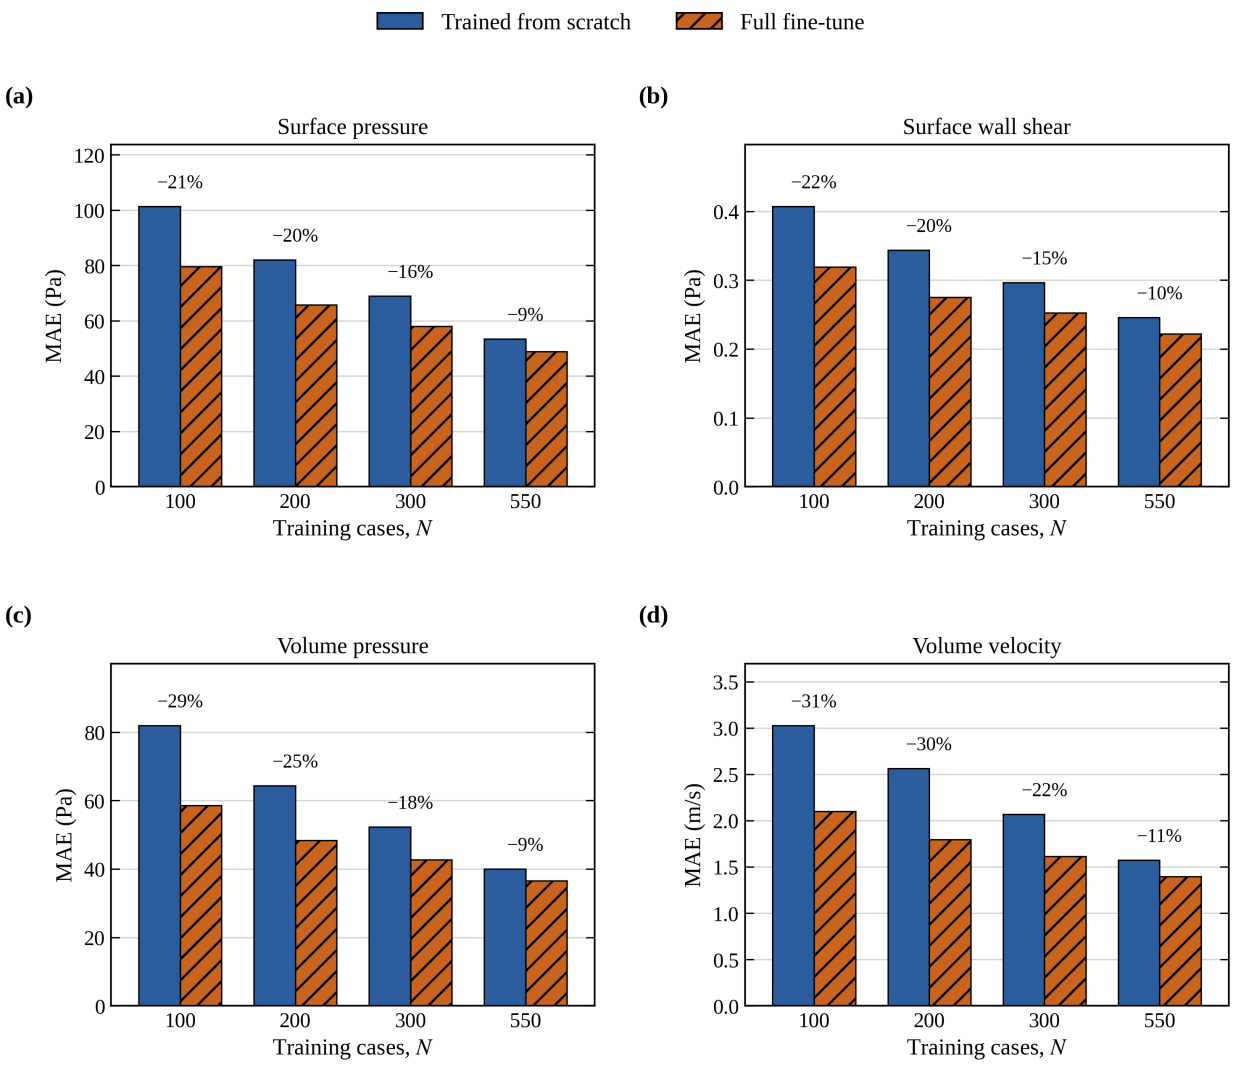

图4： 联合卡车模型的表面压力 (a)、壁面剪切应力 (b)、体积压力 (c) 和速度 (d) 平均绝对误差。百分比变化是相对于相同预算下从头训练的结果。

在全部四个场变量上均低于使用300个案例从头训练的误差。对于全部四个场变量，随着目标训练集规模扩大，微调的相对优势逐渐缩小；这与可用目标数据增多时预训练贡献减少的情况一致。

3.3 使用经验回放进行持续学习

DrivAerML 实验考察了适应新任务后，回放对基础任务预测的影响。在所有测试的记忆规模下，与不使用回放的适应相比，回放降低了 45 个留出的基础任务设计中全部四种场变量的平均绝对误差（图5）。

保留10%的基础任务训练案例使误差降低了16%至21%。在记忆规模为一半时，保留166个基础任务案例并结合31个新任务案例，使误差降低了30%至35%。将记忆规模从一半扩大到完全回放又额外提升了6至9个百分点，相较于不进行回放的适应，误差降低幅度达到36%至42%。

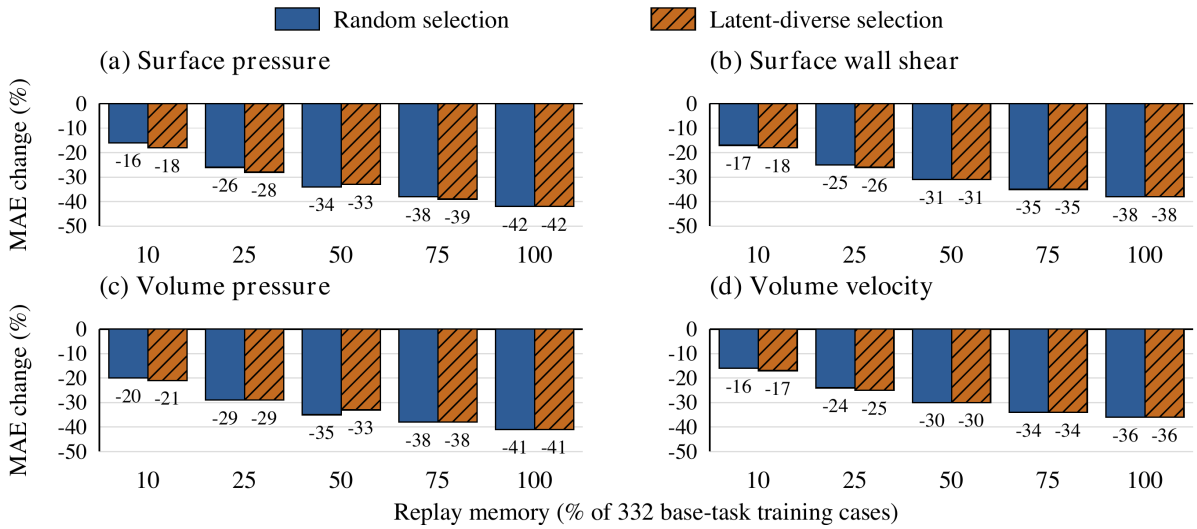

图 5： 阶段 2 适配后，在 45 个留出的 DrivAerML 基础任务设计上的场变量平均绝对误差变化，相对于不使用回放的适配结果。随机回放和潜在多样性回放在每个记忆比例下使用相同的案例数量，并共享完整记忆量下的结果。百分比变化四舍五入为整数。

在记忆规模相同的情况下，两种选择策略带来的误差降低幅度相近；在两个最小记忆规模下，潜在空间多样性选择略占优势。在10%的记忆规模下，潜在空间多样性选择使四个字段报告的误差降低幅度均提高了1至2个百分点；在25%的记忆规模下，它使其中三个字段提高了1至2个百分点，并在体积压力方面持平。当可保留的案例较少时，这种模式与覆盖更多几何嵌入空间的预期优势一致。在更大的记忆规模下，这一优势并不稳定：在50%的记忆规模下，随机选择使体积压力误差的降低幅度更大。这些细微差异反映了所报告的运行结果，并不能证明某种选择器具有统计上可靠的优势。在测试的各项设置中，误差降低幅度受保留数据量的影响大于选择策略的影响。

4 讨论

用于早期气动筛选的代理模型，必须在新车辆项目的数据库仍然很小的情况下达到实用的准确度。其目标是区分候选几何形状所对应的阻力变化，以便设计人员决定推进哪些改动。皮卡研究展示了现有检查点如何减少适配所需的新数据量。使用 100 个卡车案例对 SUV预训练模型进行微调，其四项场变量平均绝对误差均达到或优于使用 200 个案例从头训练的结果。在仅表面实验中，微调还在五个匹配的数据量中有四个降低了阻力系数平均绝对误差。

当更新后的代理模型必须继续服务于先前设计以及新设计时，就会出现另一项需求。经验回放通过在新案例之外，将选定的先前仿真纳入训练，来应对这一需求。在 DrivAerML 中，保留一半基础任务训练集，使留出的基础任务设计上的场变量平均绝对误差相较于不使用回放进行适应降低了 30% 至 35%。这一结果表明，当对先前设计的准确性仍属于建模任务的一部分时，采用回放是有益的。

5 结论

本研究评估了迁移学习和持续学习这两种互补方法，用于训练汽车空气动力学神经代理模型。迁移学习实验考察了经过运动型多用途汽车预训练的 LSMART 模型，能否以比从头训练更少的仿真次数，在皮卡上达到相近的准确性。持续学习实验则着眼于模型开发的另一阶段：更新后的代理模型必须继续服务于先前设计。在该实验中，研究者在将 DrivAerML 模型从基础任务适应至 31 个新任务案例时，评估了经验回放。主要发现如下。

- **在所有测试的训练预算下，微调都提升了场精度**。与从头训练相比，微调降低了仅表面配置和表面与体积联合配置中每个预测场的平均绝对误差（MAE）。在 100 个皮卡案例下，联合模型的四项场变量平均绝对误差降低了 21% 至 31%。

- **联合模型用更少的皮卡案例就达到了相当的场精度**。在 100 个案例上微调，所有四项场变量平均绝对误差均达到或优于使用 200 个案例从头训练的结果。在 200 个案例上微调，在所有四个场变量上也优于使用 300 个案例从头训练的结果。

- **在五种仅表面训练预算中的四种下，微调都提升了阻力预测**。在四种较大的预算下，阻力系数平均绝对误差降低了 7.1% 至 19.5%。在 100 个案例下，尽管表面场误差降低，阻力误差却有所增加。

- **适应后，经验回放提升了对早期设计的预测效果**。与不进行回放的适应相比，保留一半基础任务训练集后，在 45 个留出的基础任务设计上的场变量平均绝对误差降低了 30% 至 35%。完全回放带来的降幅为 36% 至 42%。随机选择和潜在空间多样性选择都未能持续降低误差。

比较候选几何形状两两之间预测的阻力差异与基于计算流体力学得出的阻力差异，可以检验代理模型是否捕捉到了影响设计选择的变化方向和幅度。在微调期间冻结编码器或解码器，可以检验减少更新参数是否能在保持精度的同时缩短训练时间。比较冻结编码器与冻结解码器的影响，还有助于确定已学习映射中的哪些部分可以在不同车型系列之间复用。

总的来说，这些实验展示了先前的仿真如何支持代理模型开发的两个阶段。预训练模型只需使用来自新车型系列的较少仿真，就能达到相当的场精度；而随着设计空间不断扩展，回放可以改善对早期设计的预测。通过让高成本仿真在一系列建模任务中持续发挥作用，这些方法为提高科学机器学习的数据效率提供了一条途径，并有望使神经代理模型更早应用于汽车空气动力学开发。

生成式人工智能的使用。我们使用生成式人工智能工具协助检查语法和润色文本，以提升稿件的清晰度和可读性。作者对最终稿件的准确性、完整性及内容承担全部责任。

参考文献

[1] 梅赛德斯-奔驰集团，“空气阻力更小，效率更高”，2025年9月19日，https://group.mercedes-benz.com/technology/innovation/development/aerodynamic-surplus-value.html，访问于2026年11月5日。[2] Ananthan, V., Ashton, N., Chadwick, N., Lizarraga, M., 等，“道路车辆空气动力学机器学习”，WCX SAE世界大会体验，美国密歇根州底特律，2024年4月16日，https://doi.org/10.4271/2024-01-2529。[3] Li, Z., Kovachki, N., Choy, C., Li, B., 等，“用于大规模三维偏微分方程的几何信息神经算子”，《神经信息处理系统进展》36：35836–35854，2023年，https://doi.org/10.5 2202/075280-1556。[4] Wu, H., Luo, H., Wang, H., Wang, J., 等，“Transolver：用于一般几何体上偏微分方程的快速Transformer求解器”，《第41届国际机器学习会议论文集》，PMLR 235：53681–53705，2024年，https://proceedings.mlr.press/v235/wu24r.html。[5] Ashton, N., Mockett, C., Fuchs, M., Fliessbach, L., 等，“DrivAerML：用于道路车辆外部空气动力学的高保真计算流体动力学数据集”，arXiv:2408.11969v2，2025年，https: //doi.org/10.48550/arXiv.2408.11969。[6] Elrefaie, M., Morar, F., Dai, A., 和 Ahmed, F., “DrivAerNet++：包含计算流体力学模拟和深度学习基准的大规模多模态汽车数据集”，《神经信息处理系统进展》37：499–536，2024年，https://doi.org/10.52202/079017-0016。[7] Ashton, N., Maddix, D.C., Gundry, S., 和 Shabestari, P. M., “AhmedML：用于不可压缩低速钝体空气动力学的高保真计算流体动力学数据集”，arXiv:2407.20801，2024年，https://doi.org/10.48550/arXiv.2407.20801。[8] Ashton, N., Angel, J.B., Ghate, A.S., Kenway, G.K.W., 等，“WindsorML：用于汽车空气动力学的高保真计算流体动力学数据集”，《神经信息处理系统进展》37：37823–37835，2024年，https://doi.org/10.52202/079017-1194。[9] Pan, S.J. 和 Yang, Q., “迁移学习综述”，《IEEE知识与数据工程汇刊》22(10)：1345–1359，2010年，https://doi.org/10.1109/TKDE.2009.191。[10] Keum, S. 和 Warey, A., “通过迁移学习将汽车空气动力学代理模型适配到新车型系列”，arXiv:2605.27968，2026年，https://doi.org/10.48550/arXiv.2605.27968。[11] Kirkpatrick, J., Pascanu, R., Rabinowitz, N., Veness, J., 等，“克服神经网络中的灾难性遗忘”，《美国国家科学院院刊》114(13)：3521–3526，2017年，https://doi.org/10.1073/pnas.1611835114。[12] Rolnick, D., Ahuja, A., Schwarz, J., Lillicrap, T., 等，“持续学习的经验回放”，《神经信息处理系统进展》32，2019年，https://proceedings.neurips.cc/paper/2019/hash/fa7cdfad1a5aaf8370ebeda47a1ff1c3-Abstract.html。[13] Samuel, K.M. 和 Ahmed, F., “三维工程回归问题的持续学习策略：基准研究”，《工程计算与信息科学》25(10)：101003，2025年，https://doi.org/10.1115/1.4069113。[14] Gao, B., “Luminary-SMART：大型物理模型架构的最新技术水平”，Luminary，2026年7月28日，https://luminary.ai/resources/luminary-smart-the-new-state-of-the-art-model - architecture-for-large-physics-models/，访问于2026年11月6日。[15] Luminary Cloud，“SHIFT-SUV：用于SUV外部空气动力学的高保真计算流体动力学数据集”，数据集，2025年，https://huggingface.co/datasets/luminary-shift/SUV，访问于2026年11月5日。

[16] Raut, R., Yu, Y., Mishra, A.A., Emory, M., 等：《SHIFT-Truck：皮卡车高保真空气动力学数据集与基准》，arXiv:2609.38638，2026，https://doi.org/10.48550/arXiv.2609.38638。[17] Hagnberger, J. 和 Niepert, M.：《SMART：使用基于Transformer的代理模型，根据原始几何形状进行可扩展的无网格空气动力学仿真》，《第43届国际机器学习会议论文集》，PMLR 306:39376–39420，2026，https://proceedings.mlr.press/v306/hagnberger2 6a.html。[18] Emory, M., Mishra, A., Yu, Y., Mara, M., 等：《SHIFT：三维工业流体动力学高保真基准套件》，预印本，Luminary Cloud，2026年6月，https://www.researchgate.net/publi cation/407461617，访问于2026年11月5日。[19] Chen, X., Liang, C., Huang, D., Real, E., 等：《优化算法的符号发现》，《神经信息处理系统进展》36:49205–49233，2023，https://doi.org/10.52202/0 75280-2140。[20] Qi, C.R., Yi, L., Su, H. 和 Guibas, L.J.：《PointNet++：度量空间中点集的深层次层级特征学习》，《神经信息处理系统进展》30，2017，https: // proceedings.neurips.cc/paper/2017/hash/d8bf84be3800d12f74d8b05e9b89836f-Abstract.html。[21] Pang, Y., Wang, W., Tay, F.E.H., Liu, W., 等：《用于点云自监督学习的掩码自编码器》，《计算机视觉–ECCV 2022》，《计算机科学讲义》13662:604–621，Springer，2022，https://doi.org/10.1007/978-3-031-20086-1_35。