arXiv:2303.02844v1 [physics.flu-dyn] 6 Mar 2023

用于翼型升力系数预测的知识嵌入式元学习模型

Hairun Xie[a]，Jing Wang[b,*]，Miao Zhang[a]

[a]上海飞机设计研究院，中国上海，*200436*[b]上海交通大学航空航天学院，中国上海，*200240*

摘要

气动性能评估是飞机气动设计优化过程中的重要环节；然而，传统方法成本高且耗时。尽管各种机器学习方法能够达到较高的准确度，但由于泛化性能较差且具有“黑箱”特性，它们在工程中的应用仍然困难。本文开发了一种知识嵌入式元学习模型，将数据与升力曲线的理论知识充分结合，以获取任意超临界翼型在不同攻角下的升力系数。在所提出的模型中，主网络负责表征升力与攻角之间的关系，而翼型的几何信息则编码到超网络中，以预测主网络中涉及的未知参数。具体而言，本文训练了三个具有不同架构的模型，以提供多种解释。与普通神经网络相比，所提出的模型在保持具有竞争力的预测精度的同时，展现出更强的泛化能力。随后，基于积分梯度和显著性方法进行了可解释性分析。结果表明，所提出的模型能够评估翼型几何形状对其物理特性的影响。此外，本文还对所提出模型导致的异常和不足进行了详细分析与讨论。

关键词：升力系数、知识嵌入、元学习

*通讯作者。电子邮箱：wangjinger@sjtu.edu.cn (Jing Wang)

提交至爱思唯尔的预印本 *2023*年*3*月*7*日

1. 引言

飞机的气动性能对其经济性、安全性、舒适性和环保性有着显著影响。计算流体力学（CFD）是应用最广泛的气动性能评估方法，在过去几十年中对飞机的发展发挥了至关重要的作用 [1]。传统上，CFD 仿真用于提供详细的流场，随后以积分量的形式计算气动性能。然而，仿真耗时极长，而且在优化设计过程中需要进行大量迭代仿真。因此，高效、准确地获取气动性能对于提升翼型、机翼和飞机的质量至关重要。

数据驱动代理模型已应用于预测实际工程问题中的气动性能。响应面模型、径向基函数、克里金模型和支持向量机等传统模型已得到广泛应用。然而，它们通常难以处理高维、多尺度和非线性问题。20世纪90年代，神经网络被用于实现旋翼叶片 [2]和多段翼型 [3]的优化。近年来的研究仍基于这一基本思路，并借助更大的数据集、更强的人工智能算力和更先进的深度学习算法，在更广泛的适用范围内取得更准确的结果。人工神经网络（ANN）已应用于许多研究 [4, 5, 6] ，其准确度优于传统模型。此外，一些研究人员采用卷积神经网络（CNN）架构，通过将翼型形状转换为图像来预测气动系数 [7, 8]。Peng等人[9]提出了一种人工神经网络，能够学习物理定律和气动方程，同时准确预测升力系数。更多相关文献可参见[10], ，该文综述了机器学习方法在气动外形优化中的广泛应用。然而，这些代理模型的泛化性能不足，而且它们本质上是黑箱，这使设计者对其结果缺乏信心。这可能主要归因于几何形状与气动性能之间的复杂关系，而二者通过纳维-斯托克斯（N-S）方程描述的高维流场相互关联。

近年来，随着深度学习和计算机视觉技术广泛取得成功，许多研究人员开始致力于预测

不同几何形状上的精细流场 [11, 12, 13, 14, 15, 16]。据此，可以根据预测得到的流场综合评估气动性能。Sekar 等人 [17] 设计了 CNN 和多层感知机（MLP）模型，利用提取的几何参数、雷诺数和攻角，预测翼型上的不可压缩层流稳态流场。他们发现，根据预测流场计算得到的升力系数与计算流体力学（CFD）结果吻合良好，而阻力系数则与 CFD 结果略有偏差。Wang 等人 [18]提出了一种变分自编码器，用于预测不同流动条件下超临界翼型周围的流场；根据预测流场得到的阻力系数和力矩系数，其最大相对误差分别小于 5% 和 2%。基于流场预测模型评估的气动性能可能具有更好的泛化能力，因为这些模型对不同几何形状采用一致的纳维–斯托克斯方程解作为替代方案。然而，预测精度取决于模型拟合并预测流场的能力，这高度依赖训练数据，而且可能产生不切实际或较差的预测结果，与计算流体力学结果相差甚远。具体而言，网络难以准确表征变化剧烈的区域，例如用于计算气动性能的表面压力，这可能导致相对较大的误差。

提升数据驱动模型性能的策略在于增强其输入信息，即提供更丰富的数据以及更本质的先验信息或领域知识。鉴于在本研究中获取数据成本高且耗时，领域知识和先验信息因此成为一种很有前景的替代方案。通过同时利用领域知识和数据信息，该模型既能发挥数据驱动模型强大的拟合能力，又具备专家系统的稳定性。这样可以克服数据驱动模型泛化性能差且缺乏可解释性的问题，从而使未来在航空领域实现人工智能可信性成为可能[19, 20]。本研究旨在开发一种知识嵌入式元学习模型，以获取任意超临界翼型在不同攻角下的升力系数，并充分融合数据与升力曲线的理论知识。在所提出的模型中，主网络负责表示升力与攻角之间的关系，而几何信息则被编码至超网络中，以预测主网络所涉及的未知参数。采用这种架构，

翼型升力的理论知识被嵌入神经网络中，使模型在保持高准确度的同时具备强大的泛化性能。进一步开展可解释性分析，以评估翼型几何形状对物理特性的影响。

本文的具体内容组织如下。第2节介绍本研究涉及的基础知识和详细方法。第3节展示气动系数预测性能，并讨论模型的可解释性。第4节给出总结性结论与讨论。

2. 方法论

本节首先讨论有关升力的经典理论知识，然后介绍神经网络模型架构，最后描述本研究涉及的详细数据集。

2.1. 升力的理论知识

薄翼型理论是20世纪20年代发展起来的最早的翼型升力分析理论之一，在早期航空实践中发挥了重要作用[21, 22]。薄翼型理论利用涡层模拟翼型的气动特性。涡层由沿翼型弦长连续分布的涡构成。由涡分布的解析表示推导出的 C_L 与迎角之间的关系如下所示。

$$C_L = (C_{L_0}) + \frac{dC_L}{d\alpha}\alpha = \pi\left(A_1 - 2A_0\right) + 2\pi\alpha \tag{1}$$

其中， A_0 和 A_1 是弯度线斜率的傅里叶级数系数， C_{L0} 是零攻角下的升力系数。升力曲线斜率表示升力随迎角变化的快慢，对于所有薄翼型，该值2π 都相同，不受厚度和弯度分布的影响。该理论基本解释了升力的产生机制，并给出了升力曲线斜率的理论最大值。然而，该理论仅适用于小迎角下弯度较小的薄翼型，且只适用于理想不可压缩流体的定常流。

对于可压缩流，存在一种基于马赫数的修正关系：

$$C_L = \frac{C_{Li}}{\sqrt{1 - M_\infty^2}} \tag{2}$$

其中， C_{Li} 是根据公式（1）计算得到的不可压升力系数， M_∞是自由来流马赫数。然而，诸如厚度和黏度等更复杂因素的影响仍被忽略。

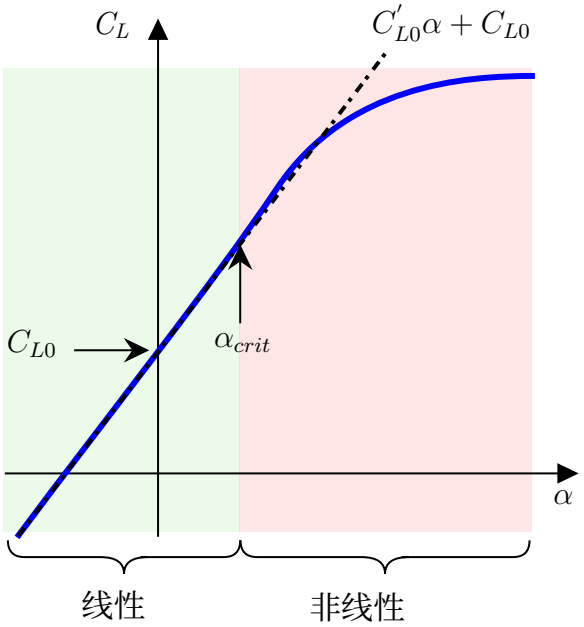

图1：实际中的典型 $C_L - \alpha$ 曲线。

图1展示了实际中的典型 $C_L - \alpha$ 曲线。当迎角较小时，该曲线与线性假设较为吻合。随着迎角增大，激波强度趋于增强，附着流开始出现分离。当迎角增大到一定程度时，激波和流动分离强烈到足以相互作用，从而导致抖振或失速。这些流动现象具有显著的非线性特征，并可能导致升力曲线偏离线性假设。因此，实际升力曲线可以分为符合线性假设的线性部分和偏离线性假设的非线性部分。实际升力曲线可由以下物理参数描述：

1) C_{L0}： $AoA = 0°$时的 C_L 值。对于对称翼型，该值为 0；对于下弯翼型，该值小于 0。对于弯度较大的翼型，该值可能大于 1.0。

2) C'_{L0}：升力曲线线性部分的斜率。对于不可压缩流，可以直接推导出理论值；而对于可压缩流，则需要进行修正或推导更复杂的关系。

3) α_{crit}：从线性部分过渡到非线性部分的转折点。目前仍缺乏对这一参数的理论研究。

尽管上述理论给出了迎角与升力之间的关系，但翼型几何形状对升力曲线的影响仍值得进一步研究。例如，公式（1）中的薄翼型理论指出，C_{L0} 仅由翼型弯度决定。然而，在工程实践中，C_{L0} 会受到其他未知复杂因素的影响，且弯度线相同的翼型也可能呈现不同的 C_{L0}。此外，几何形状与某些复杂特征（如抖振起始升力系数）之间的映射关系几乎无法预测。因此，本研究旨在利用神经网络建立几何形状与 C_L 之间的关系。

2.2. 模型架构

考虑一个监督学习问题：将翼型几何形状 $x \in \mathbb{R}^m$ 和迎角 α 作为输入，以预测对应的 C_L。为利用第 2.1 节介绍的理论，本文提出了图 2 所示的元学习模型，该模型由主网络和超网络组成。

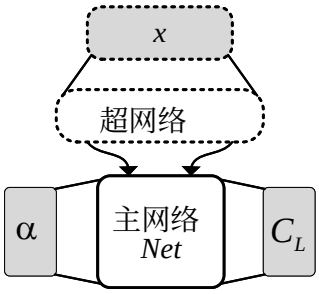

图 2：所提出模型的示意图。

主网络旨在学习 α 与C_L之间的关系。根据理论知识，升力曲线可分为线性部分和非线性部分，分界点为 α_{crit}。线性部分

可用斜率 w_{lin} 和截距 b_{lin}表示。为确保各参数处于适当范围， w_{lin} 和 b_{lin} 分别由前文讨论的C'_{L0} 和 C_{L0}经归一化得到。

对于非线性部分，可以使用多层感知器（MLP）拟合其相对于线性部分的非线性偏差。鉴于当 $\alpha < \alpha_{crit}$ 时非线性部分应处于非激活状态，具有（$\alpha - \alpha_{crit}$）作为输入的修正线性单元（ReLU）激活函数 $f(x) = max(0, x)$ 是最明显的选择。在本研究中，我们选择以下 Softplus函数。该函数是 ReLU 函数的平滑近似，从而确保升力曲线平滑且可微，

$$\text{modSoftplus}\,(x) = \frac{\log\left(1 + e^{10x}\right)}{10} \tag{3}$$

因此，主网络表示为：

$$f(\alpha;\theta) = \overbrace{w_{lin}\alpha + b_{lin}}^{\text{linear}} + \overbrace{f_{\text{MLP}}\left(\text{modSoftplus}(\alpha - \alpha_{crit})\,; W_p\right)}^{\text{non-linear}} \tag{4}$$

其中， $f_{\text{MLP}}: \mathbb{R} \mapsto \mathbb{R}$ 是一个 MLP，其权重和偏置表示为$W_p \in \mathbb{R}^{N_{W_p}}$。主网络中的未知参数 θ 包括w_{lin}， b_{lin}， α_{crit} 和 W_p。

为了明确编码翼型信息，使用第二个网络（称为超网络）来学习从翼型几何形状到主网络未知参数的映射。超网络由一个 MLP 网络构成，表示如下：

$$\theta = g_{\text{MLP}}(x; W_h) \tag{5}$$

其中， $g_{\text{MLP}}: \mathbb{R}^m \mapsto \mathbb{R}^{N_{W_p}+3}$ 是一个多层感知机，其权重和偏置表示为 $W_h \in \mathbb{R}^{N_{W_h}}$。

模型的损失函数计算遵循元学习方法[23, 24]。对于这些回归任务，采用均方误差（MSE）。主网络执行任务 $\mathcal{T}$，而每个翼型对应的任务记为 $\mathcal{T}_i$。相应地，每个翼型对应的主网络参数记为 θ_i 。主网络中每个任务的损失形式如下：

$$\mathcal{L}_{\mathcal{T}_i} = \sum_{\alpha_{(j)} \sim \mathcal{T}_{(i)}} \left\| f\left(\alpha_{(j)}; \theta_{(i)}\right) - C_{L(j)} \right\|_2^2 \tag{6}$$

将超网络的作用纳入损失函数后，通过最小化以下总损失来训练图 3 所示的网络：

$$\mathcal{L}_{total} = \sum \mathcal{L}_{\mathcal{T}_i} = \sum_{\mathcal{T}_{(i)}} \sum_{\alpha_{(j)}} \left\| f\left(\alpha_{(j)}; g\left(x_{(i)}, \phi\right)\right) - C_{L(j)} \right\|_2^2 \tag{7}$$

此外，还采用平均绝对误差（MAE）和最大绝对误差（MAXE）作为评估指标，以反映模型的预测精度。

2.3. 数据集

数据集包括翼型几何形状及其对应的 $C_L - \alpha$曲线，位于 $Ma = 0.73$, $Re = 5.0 \times 10^6$。为确保数据集的可用性和多样性，在采样翼型几何形状时施加了若干约束，例如前缘半径不得小于0.007，且翼型的最大厚度应限制在一定范围内。本研究共采样了2000个翼型，其中80%作为训练集，20%作为测试集。为促使网络准确学习 $C_L - \alpha$ 曲线的显式参数，对迎角进行了密集采样，每个翼型包含约50个迎角。采样得到的翼型及 $C_L - \alpha$ 的分布如图4所示。可以看出，该数据集涵盖了广泛的超临界翼型和气动性能。

计算域为一个半径为 $30c$ 的二维网格，其中 $c = 1.0$ 为翼型的弦长。图 5 所示的结构化 O 型网格在环绕方向和法向方向上的尺寸分别为 385×193。在翼型曲率变化显著的位置（如前缘和后缘）进行周向网格加密。通过适当设置第一层网格高度，翼型表面的 y^+ 小于 1。

雷诺平均纳维-斯托克斯（RANS）模拟采用剪切应力输运（SST）湍流模型，并使用开源代码 CFL3D 求解。采用守恒律单调迎风中心格式确定单元界面处状态变量的插值，使用 Roe 格式进行空间离散，并采用对称高斯-赛德尔下上迭代法推进时间。通过考察设计流动条件下基准 RAE2822 翼型的气动特性，评估数值格式的有效性。将压力分布与计算流体力学

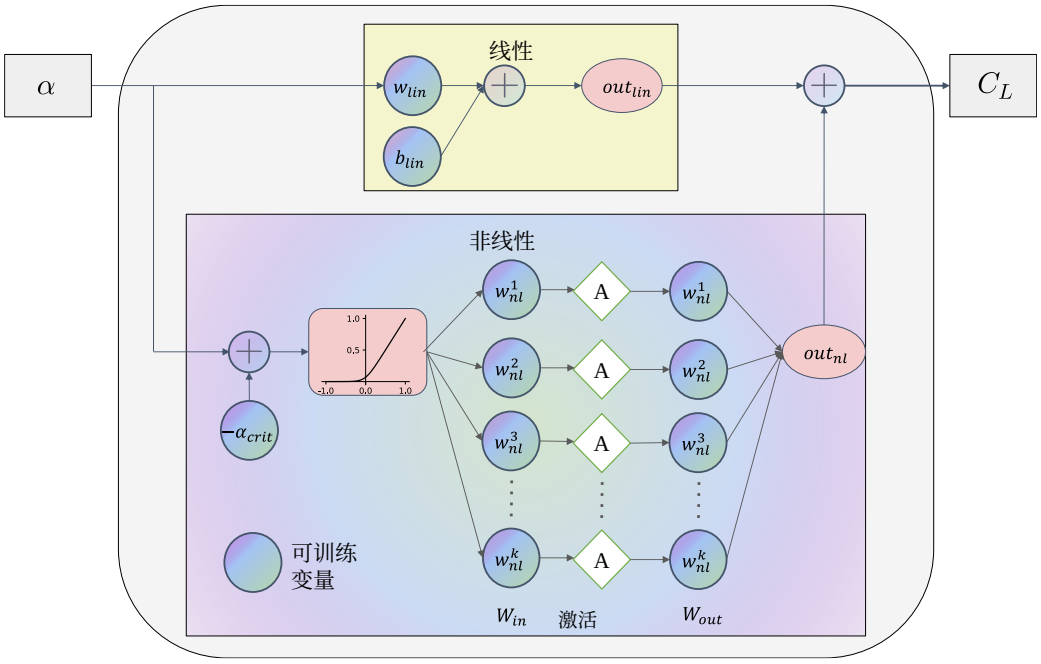

(a) 主网络

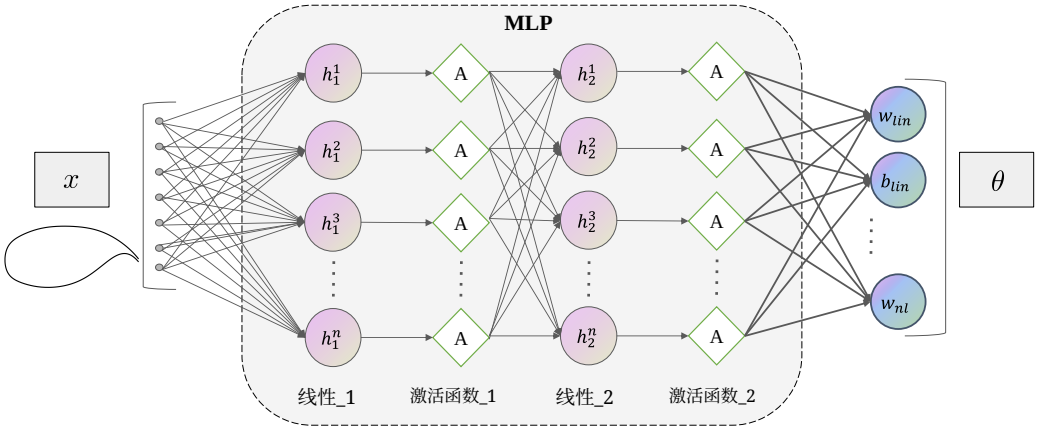

(b) 超网络

图 3：翼型气动性能预测的网络架构。

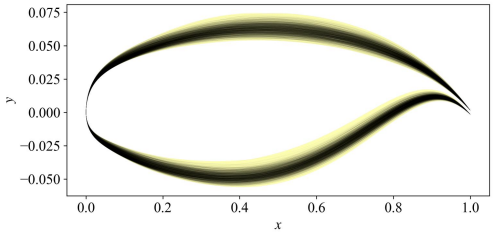

(a) 采样翼型几何形状。

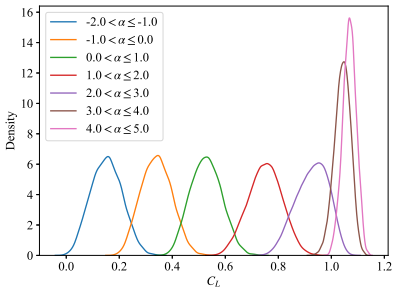

(b) C_L 分布 at 不同迎角。

图 4：数据集详情。

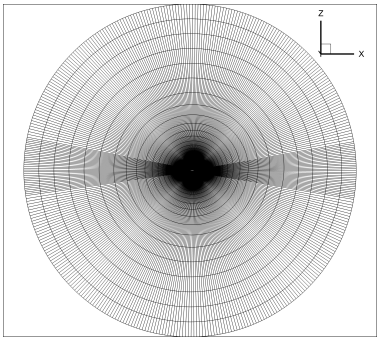

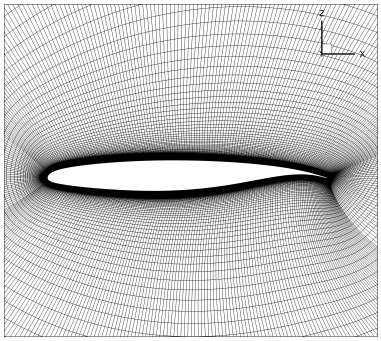

图 5：用于数值模拟的结构化 O 型网格。

计算结果与图 6 中的实验结果。结果表明，计算流体力学计算能够达到较高的准确度，流场等值线表明网格设置能够捕捉主要的流动结构。

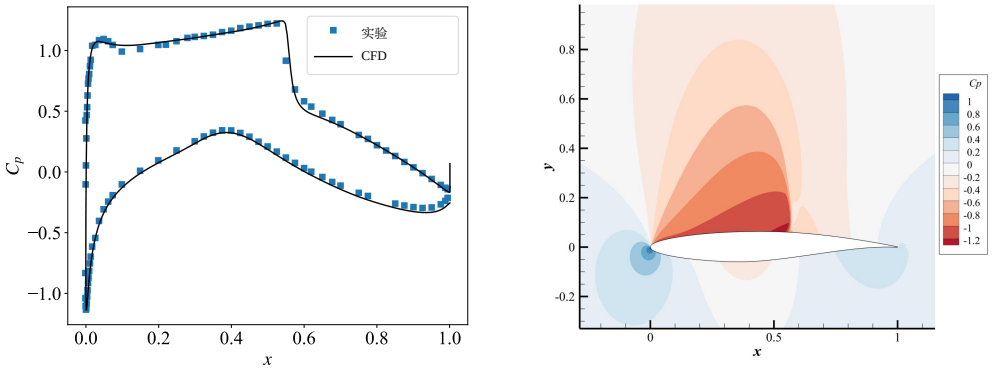

（a）表面压力与实验结果对比

（b）流场等值线

图 6：RAE2822 翼型的计算流体力学模拟。

3. 结果与分析

本节首先展示模型的性能。随后，讨论模型的可解释性及相应结果。最后，进一步分析误差较大的异常情况。

3.1. 预测结果

本研究设计并比较了三个模型，以考察所提出架构的性能。(1) **基础模型：** 主网络采用 1 个包含 10 个单元的隐藏层，后接 Tanh 激活函数；超网络采用 2 个包含 128-128 个单元的隐藏层，后接 Softsign 激活函数。(2) **+权重衰减：** 将权重衰减项（即权重平方和）加入基础模型的损失函数，以促进权重稀疏，并简化 α 与 C_L之间的关系。(3)**-激活：** 假设翼型几何形状与C'_{L0}、 C_{L0}、 α_{crit}、 W_p 之间呈线性关系，则停用基础模型中超网络的激活函数。

上述所有模型均使用 Adam 优化器进行训练。采用学习率预热，初始学习率设为 4×10^{-4}。三个模型的收敛历史如图 7 所示。训练误差和测试误差在前 250 个训练轮次中均迅速下降，随后稳步下降。经过 2000 个训练轮次后，误差收敛至 10^{-3} 量级。正如预期，基础模型的误差最低，其次是 - 激活和 +权重衰减。测试损失与训练损失的变化趋势一致，但测试曲线的波动明显更大。

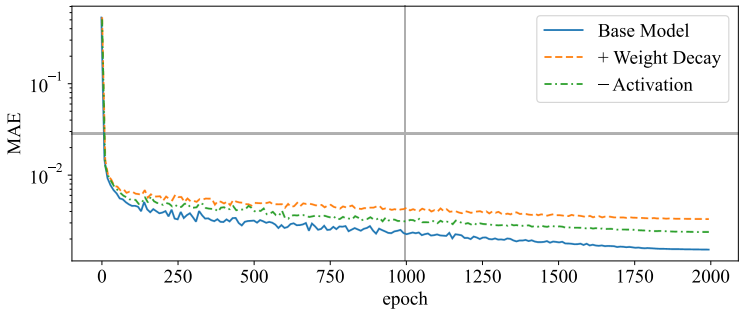

(a) 训练损失

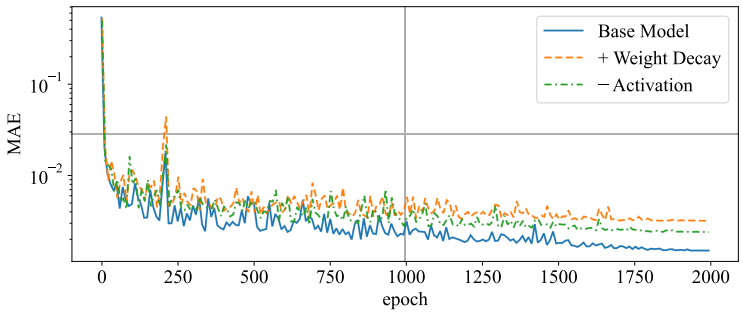

(b) 测试损失

图 7: 不同配置的收敛曲线。

为突出所提出方法的精度和泛化能力，我们引入另一个标准的全连接神经网络（记为**人工神经网络**）进行比较。该网络由 2 个隐藏层组成，单元数为 258-128-128-1，是一个完全的“黑箱”模型。四种模型的收敛误差汇总于表 1。平均绝对误差反映模型的精度，

而最大绝对误差反映模型对不同样本的稳定性，表明我们对模型的信任程度。比较训练误差时，人工神经网络的表现最佳，其平均绝对误差和最大绝对误差均为最低。然而，人工神经网络的测试误差最大，其中测试平均绝对误差是训练平均绝对误差的两倍多，测试最大绝对误差则接近训练最大绝对误差的 5 倍。其他研究也发现了类似结果[25, 26], ，例如训练损失为 0.36484，测试损失为 0.06415。这表明人工神经网络模型建立的是局限于训练样本的局部映射，而非通用的全局映射。

相比之下，另外三个模型的训练误差和测试误差相当，其中测试误差均低于**人工神经网络**。例如，基础模型、 +权重衰减和-激活中，训练平均绝对误差与测试平均绝对误差的比值分别为1.004、0.984和0.990。训练最大绝对误差与测试最大绝对误差的比值分别为0.885、0.689和0.711。此外，图8展示了三个模型的平均绝对误差概率密度分布，符合正态分布规律。训练样本误差与测试样本误差几乎完全相同。由于大多数样本的平均绝对误差较低，基础模型表现出优于其他模型的精度。因此，所提出的模型展现出出色的泛化能力，并且在各种样本上的表现同样良好。初级网络中的通用知识嵌入可能是泛化性能显著提升的原因。相反，当预设条件不满足时，数据可能会消除知识与现实之间的差异，从而提高模型的准确度。因此，双驱动模型受益于知识和数据，实现了综合优势。

表 1：不同模型的比较

	训练		Test	
	MAE	MAXE	MAE	MAXE
基础模型	1.511E-03	5.989E-02	1.517E-03	5.299E-02
+权重衰减	3.304E-03	1.615E-01	3.252E-03	1.112E-01
-激活	2.427E-03	1.365E-01	2.402E-03	9.710E-02
ANN	1.467E-03	3.282E-02	3.457E-03	1.611E-01

随机选取了九个测试样本，以展示模型的性能。图9-11展示了三个模型预测的升力曲线，以及通过超网络获得的C'_{L0}、 C_{L0} 和 α_{crit} 。

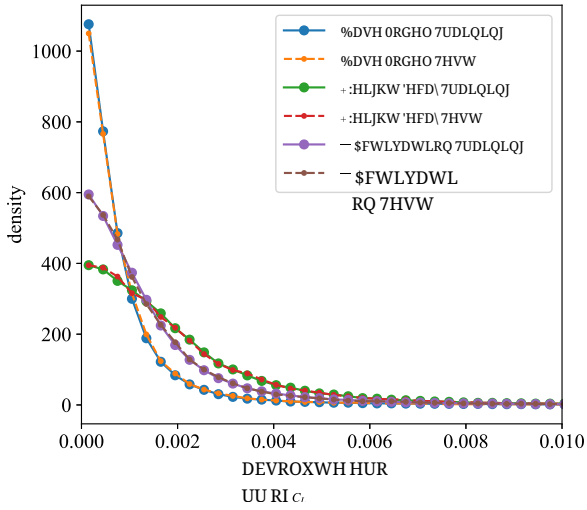

图8：预测结果的误差分布。

对于大多数样本，预测的升力曲线与实际升力曲线吻合良好，线性部分和非线性部分都得到了同样准确的拟合。对于**基础模型**，只有样本-g在非线性部分存在明显误差。对于 **+权重衰减** 模型，样本-b/e/g/i在非线性部分的误差相对较大。对于**-激活** 模型，样本-b和样本-g的线性部分拟合得不太理想。样本-g预测效果不佳的原因是它位于分布区间的边缘附近，可视为离群值；这一点我们将在后文详细讨论。

图12展示了通过三个模型的超网络获得的 C'_{L0}、 C_{L0} 和 α_{crit} 的分布统计。对于 C_{L0}，各分布相当一致，表明三个模型的预测结果几乎等效。证据还表明， C_{L0} 与几何形状之间的关系是单调的，可以通过线性映射或具有稀疏权重的非线性映射来表示。对于 C'_{L0} 和α_{crit}，–激活的分布与其他分布存在偏差。这表明C'_{L0}、 α_{crit} 与几何形状之间的关系更为复杂且具有非线性，因此难以通过线性映射精确表示。令人欣喜的是， +权重衰减的分布与基础模型相对相似，这有助于以简化的方式理解这种关系。

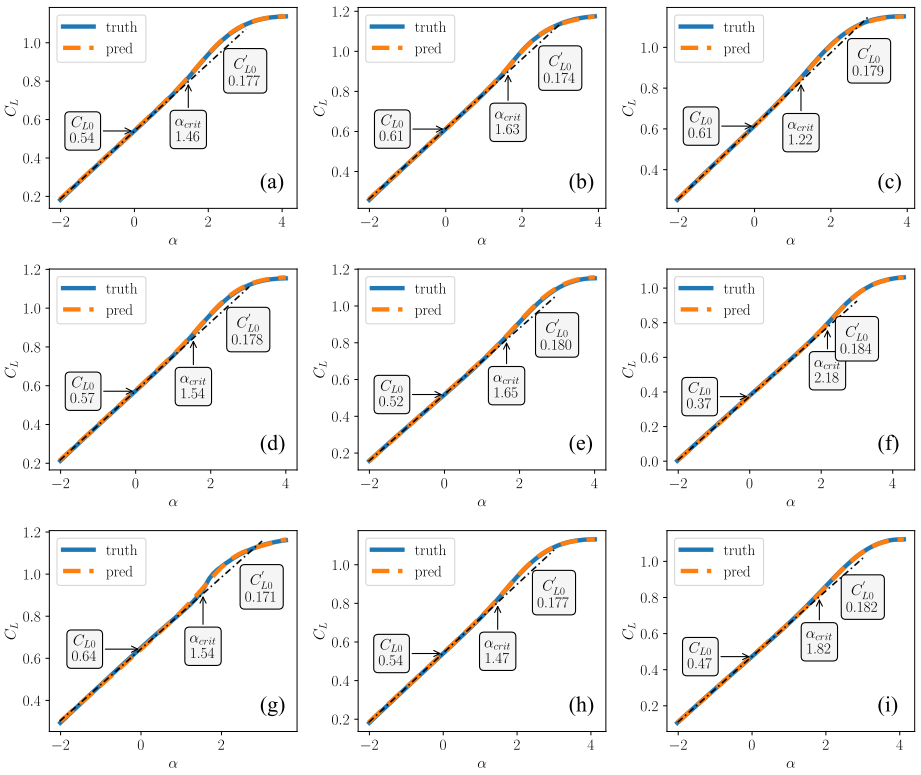

图 9：**基础模型**的预测样本。

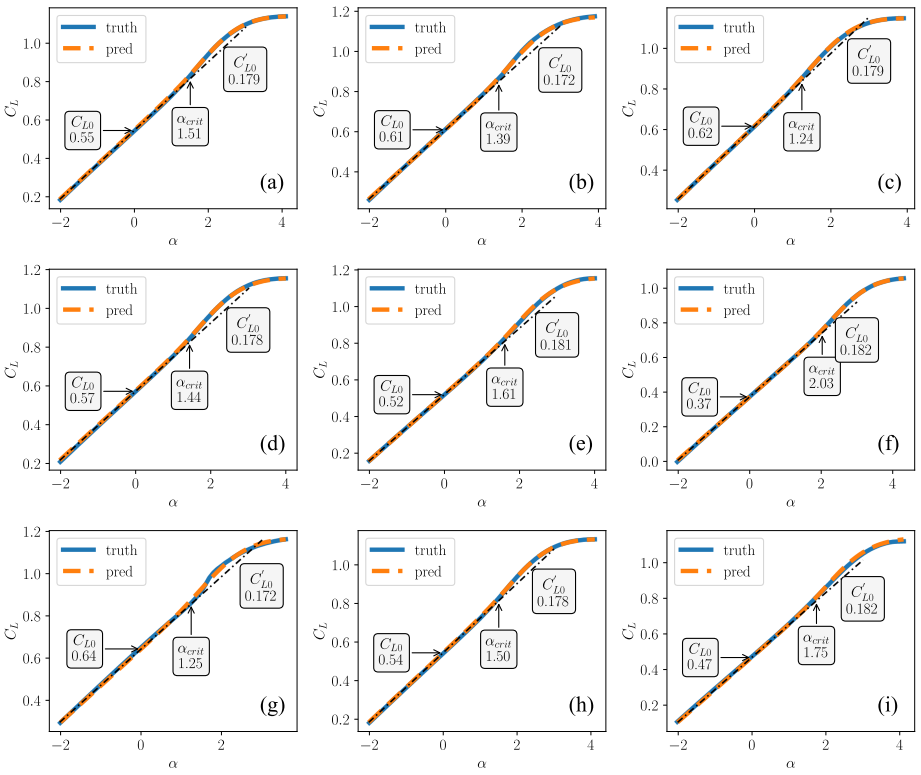

图 10： **+权重衰减**的预测样本。

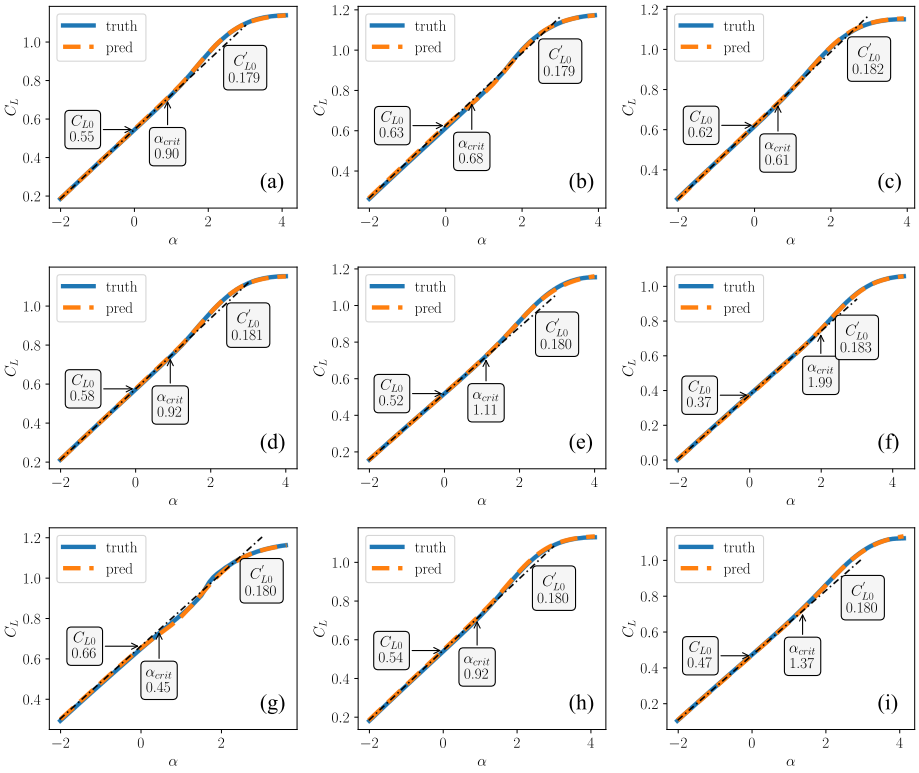
truth
pred
(a)
C_{L0} 0.55
α_{crit} 0.90
C'_{L0} 0.179
(b)
C_{L0} 0.63
α_{crit} 0.68
C'_{L0} 0.179
(c)
C_{L0} 0.62
α_{crit} 0.61
C'_{L0} 0.182
(d)
C_{L0} 0.58
α_{crit} 0.92
C'_{L0} 0.181
(e)
C_{L0} 0.52
α_{crit} 1.11
C'_{L0} 0.180
(f)
C_{L0} 0.37
α_{crit} 1.99
C'_{L0} 0.183
(g)
C_{L0} 0.66
α_{crit} 0.45
C'_{L0} 0.180
(h)
C_{L0} 0.54
α_{crit} 0.92
C'_{L0} 0.180
(i)
C_{L0} 0.47
α_{crit} 1.37
C'_{L0} 0.180
C_L
α

图11：**-激活**的预测样本。

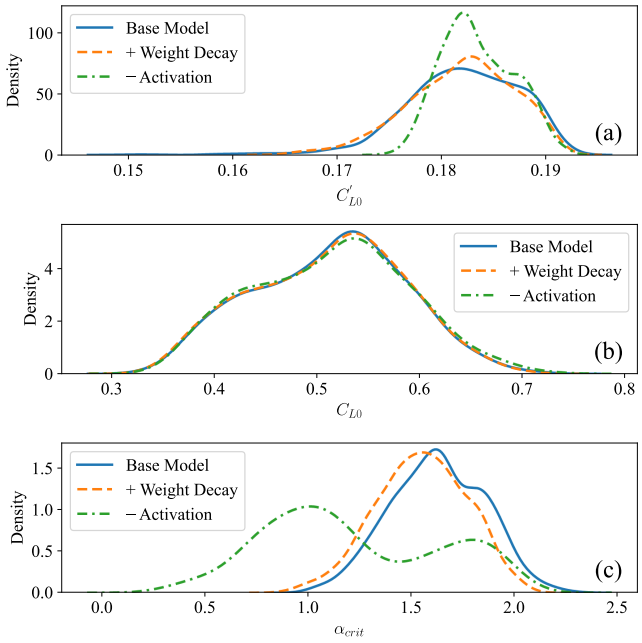

图12：主网络中关键参数的分布。

3.2. 可解释性分析

在本节中，我们尝试对模型及其结果进行解释，以理解模型产生这些结果的方式，并探究能否通过模型发现知识。主网络基于升力曲线的理论知识进行设计，其中若干可训练参数，即 C'_{L0}、C_{L0}、α_{crit}，具有明确的物理意义。超网络表示翼型几何形状对物理参数的影响，并训练了三个模型，以增强这种关系的可解释性。基础模型由于其全面的非线性映射而难以解释。 +权重衰减模型实现了稀疏权重，并捕捉了主要关系，同时省略了次要关系。-激活模型建立了从几何形状到 C'_{L0}、C_{L0}、α_{crit} 的线性映射，可用于研究所有样本中各坐标的总体贡献。

图 13 展示了三个模型中超网络的权重。输入层的权重可以反映几何形状中各部分对输出的贡献。在基础模型中可以看出，上表面和下表面的后段具有相对较大的权重。加入权重衰减项后，权重表现出显著的稀疏性，超网络也基本简化为更小的规模。-激活模型呈现出与基础模型高度相似的权重。然而，由于缺少激活函数，该模型详细描述局部变化的能力有限。

为了更好地理解翼型几何形状如何影响物理特性，本研究选取了 C_{L0} 以及一个新参数 $C_{L\ crit}$（表示 α_{crit}处的升力系数），进行进一步分析。$C_{L\ crit}$ 反映了无分离流能够产生的线性部分最大升力，这与抖振和失速特性密切相关。为了获得各输入对输出的贡献，本研究采用了积分梯度（IG）[27]和显著性方法。IG 是一种公理化的模型可解释性算法，用于根据给定的基线／参考值评估各输入对输出的重要性得分，并满足两个基本公理：敏感性和实现不变性。此外，IG 还具有完备性，即各归因值之和等于输入处的输出与基线输出之差。显著性是一种基线方法，通过计算输出相对于输入的梯度来获得输入的贡献[28]。研究从图 14 所示的测试数据集中选取了若干样本，进行 IG 和显著性分析。

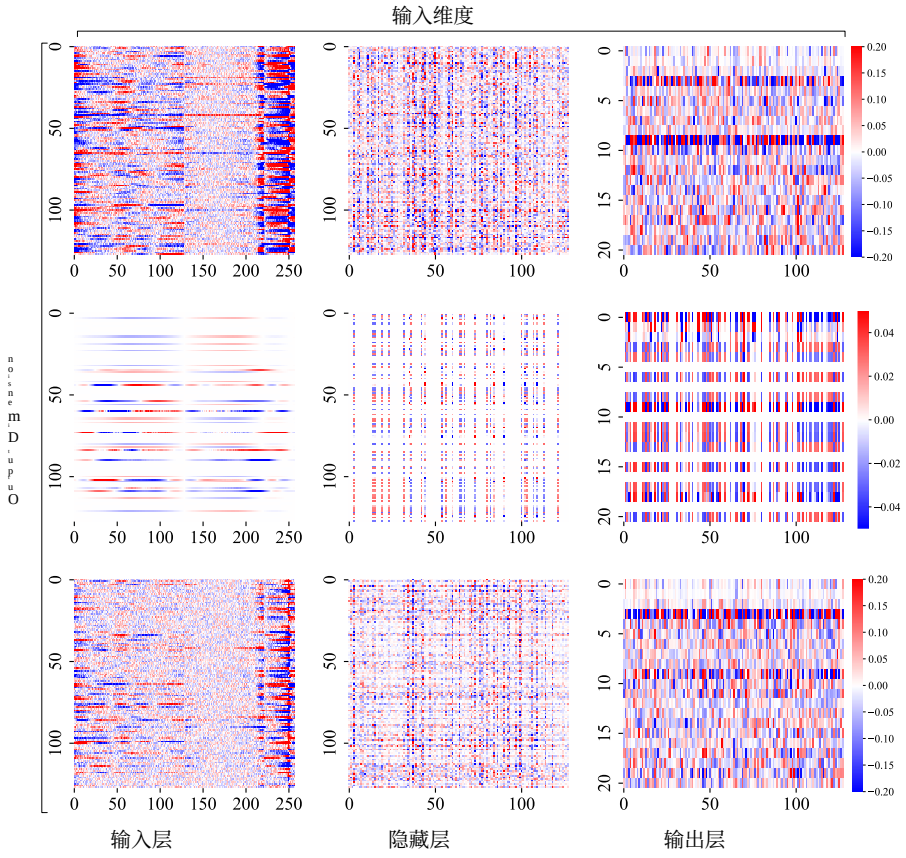

图13：超网络权重的可视化。

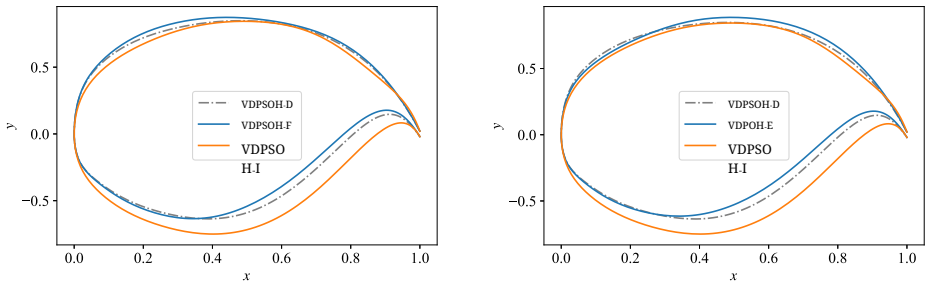

（a）变化翼型 C_{L0}　　（b）变异翼型 $C_{L\ crit}$

图14：用于可解释性分析的翼型。

首先，我们探讨 C_{L0} 与几何形状之间的关系。基础模型获得的图14(a)中样本-a/c/f的C_{L0} 分别为0.54、0.61和0.37。以样本-a为参照，样本-c表现出更高的C_{L0} ，而样本-f表现出更低的 C_{L0}。图15展示了三个模型获得的对 C_{L0} 的输入归因。如预期所示，基础模型和-激活获得的IG曲线及显著性曲线具有高度一致性。 +权重衰减获得了振荡更少、平滑得多的曲线，是用于解释的最优模型。从显著性曲线可以看出，下表面的后段对 C_{L0} 具有最大的正向影响，这与IG曲线中的明显变化相对应。上表面的正归因位于 $0.1c$ 至 $0.7c$范围内，而负归因位于 $0.7c$ 至 $0.9c$范围内。这一点也可在IG曲线中观察到，且下表面呈现出更显著的影响。对于翼型的前缘部分（$< 5\%c$），上、下表面在显著性曲线中呈现相反的归因，这表明较小的前缘半径更有利于 C_{L0}。然而，如IG曲线所示，前缘部分的贡献可以忽略不计，因为显著性的绝对值与厚度之间仅存在微小差异。上述发现表明，上、下表面的所有变化都与翼型的弯度线密切相关，尤其是考虑到下表面对超临界翼型曲率具有更大影响这一关键事实。

然后，我们探讨 $C_{L\ crit}$ 与几何形状之间的关系。基础模型得到的样本 a/b/f 的 $C_{L\ crit}$ 分别为 0.7984、0.8956 和 0.7724。以样本 a 为参照，样本 b 的 $C_{L\ crit}$更高，而样本 f 的 $C_{L\ crit}$更低。三个模型得到的对 $C_{L\ crit}$ 的输入归因如图 16 所示。与 C_{L0}不同，三个模型得到的 $C_{L\ crit}$ 的 IG 曲线和显著性曲线彼此有所差异。正如预期，基础模型学到了最全面的关系，能够针对不同样本进行局部适应。-激活模型在不同样本中呈现相同的显著性曲线，只能以复杂的全局方式进行描述。 +权重衰减模型通过消除较小的影响（例如翼型上表面的前缘部分），保留了主要影响，是最适合用于解释的模型。从显著性曲线可以看出，翼型下表面对$C_{L\ crit}$有正向影响。至于 IG 曲线，由于样本 b 和样本 f 的变化方向相反，其下表面产生了方向相反的归因。对于前缘附近的上表面

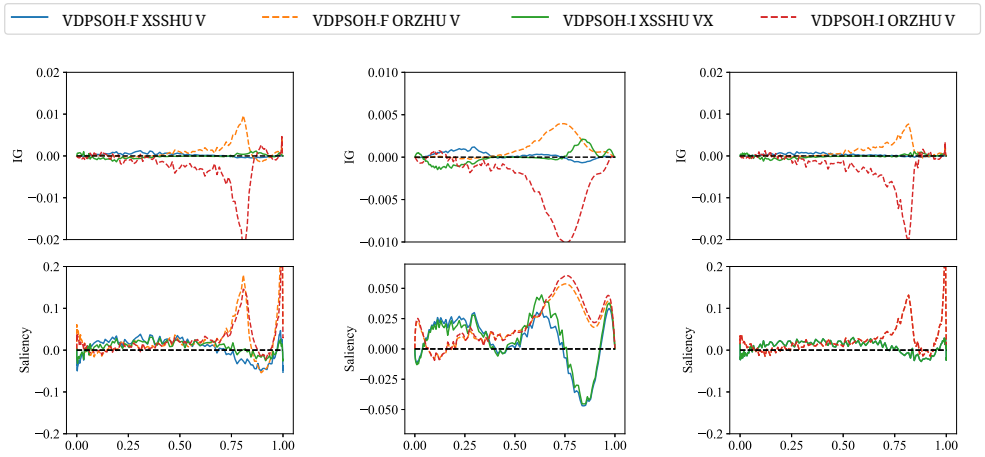

(a) 基础模型 (b) +权重衰减 (c) -激活

图 15： C_{L0}的可解释性分析。

部分（$< 25\%c$），基础模型得到的显著性曲线中出现负归因，这是由样本 b 和样本 f 在该区域向下偏移所致。对于样本 f，下表面的贡献比上表面更显著，因此其 $C_{L\ crit}$ 低于样本 a。基于上述分析，所提出的模型能够对不同几何形状进行局部解释，从而为局部优化问题提供指导。

3.3. 异常情况

在上述研究中，样本-g的表现相对较差，我们希望进一步探究其原因。图 17 展示了样本-g在不同迎角下的详细流场。当 $AoA = -1°$ 时，上表面会出现一道较弱的激波，其强度随迎角增大而逐渐增强。当 $AoA = 1°$时，前缘附近的上表面会出现第二道激波。当 $AoA = 2°$ 时，两道激波随着各自范围的扩大而合并为一道强激波。在工程设计中，双激波是一种不理想的流动现象，可能导致流动损失，并使其在其他流动条件下的表现不佳。一方面，小迎角下出现第一道激波表明存在压缩效应，这可能导致流动较早偏离线性假设。另一方面，双激波的融合过程

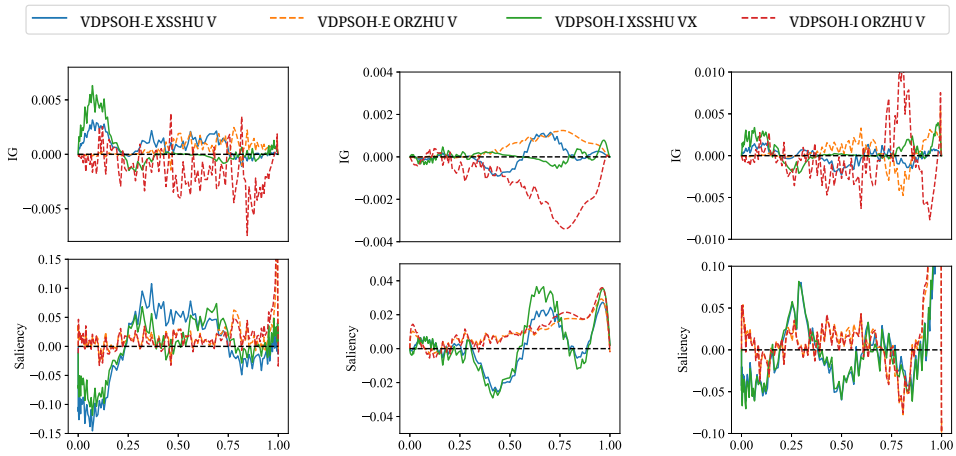

(a) 基础模型 (b) +权重衰减 (c) -激活

图 16: $C_{L\ crit}$ 的可解释性分析。

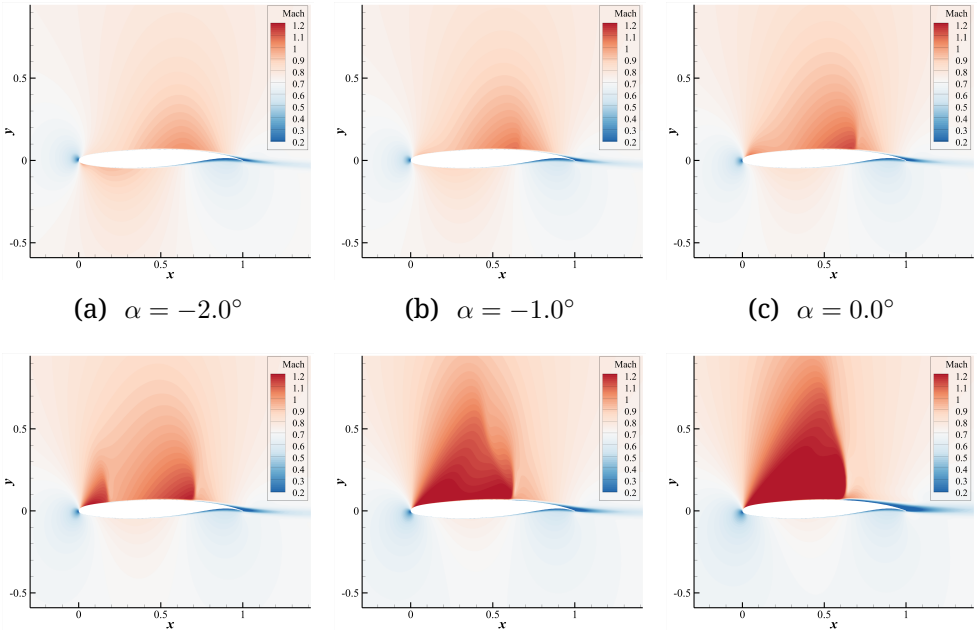

(a) $\alpha = -2.0°$ (b) $\alpha = -1.0°$ (c) $\alpha = 0.0°$

(d) $\alpha = 1.0°$ (e) $\alpha = 2.0°$ (f) $\alpha = 3.0°$

图17：样本-g在不同迎角下的流场。

这是一种典型的非线性变化，会导致升力曲线斜率发生异常变化。因此，模型可能难以实现准确预测。

在这种情况下，知识嵌入模型的不足之处得以凸显。如果知识无法充分表征数据，基于知识的网络架构在某些离群值上可能会表现受限。反过来，这可以引导我们识别导致性能不佳的关键因素，而这些因素在“黑箱”模型中几乎无法获得。因此，上述发现将有助于发展适用于双激波波型的升力曲线相关理论。此外，我们还可以分析易受双激波影响的翼型特征，并将这些样本从数据集中排除。以基础模型为例，如果排除包含双激波的测试样本（占全部测试样本的 **4.8%**），平均绝对误差将 1.274×10^{-3}降低 **16.0%**，最大绝对误差将 3.002×10^{-2} 降低 **56.7%**。如果不将这些不理想的样本纳入训练，还可以取得更显著的改进。

4. 结论

本文提出了一种知识嵌入元学习模型，用于预测超临界翼型在不同迎角下的升力系数。设计了三种模型，分别称为基础模型、 +权重衰减和-激活，以提供不同的解释。统计结果表明，基础模型的准确度最高，平均绝对误差低至 1.517×10^{-3}，其次是-激活和 +权重衰减。模型的训练误差和测试误差相近，表明其具有出色的泛化性能。主网络使我们能够获得升力曲线的若干物理特征，例如 C'_{L0}， $C_{L\ crit}$。通过可解释性分析，可以评估特定翼型几何形状对这些特征的影响。例如，下表面的后半部分对 C_{L0}具有最大的正向影响，这有助于设计者以正确的方式修改形状。

更重要的是，本文尝试将经典理论知识融入模型架构的设计中。在气动设计乃至更广泛的工程领域，数十年甚至数百年来积累并验证了一些理论。尽管其中有些理论并不具有普适性，但在特定情况下却极具适用性和有效性。将人工智能

算法与这些领域知识深度融合，可以进一步增强其表达能力和可靠性，也为未来人类与机器协同创新提供了一种可能的方向。

尽管如此，所提出的方法仍存在一些局限性，有待未来进一步研究。在某些情况下，知识可能会成为限制因素，尽管在大多数情况下，它有助于构建更强大的模型。因此，如何更合理地利用知识，甚至通过数据发现普适性知识，值得进一步研究。

参考文献

[1] F. T. Johnson、E. N. Tinoco、N. J. Yu，《波音商用飞机公司 CFD 的开发与应用三十年》，西雅图，《计算机与流体》34 (10) (2005) 1115–1151。 doi:https://doi.org/10.1016/j.compfluid.2004.06.005.[2] W. Lamarsh、Ii、J. Walsh、J. Rogers，《使用神经网络进行旋翼叶片气动性能优化》，载于：第四届多学科分析与优化研讨会，美国航空航天学会，克利夫兰，美国，1992，第 1–15 页。 doi:10.2514/6.1992-4837。网址 https://arc.aiaa.org/doi/10.2514/6.1992-4837[3] R. M. Greenman、K. R. Roth，《利用神经网络对多段翼型进行 高升力优化设计》，《流体工程杂志》121 (2) (1999) 434–440。 doi:10.1115/1.2822228.[4]N. R. Secco、B. S. d. Mattos，《利用人工神经网络预测运输机的气动系数》，《航空器工程与航空航天技术》89 (2) (2017) 211–230。doi:10.1108/AEAT-05-2014-0069.[5] M. A. Bouhlel、S. He、J. R. R. A. Martins，《用于亚音速和跨音速区域翼型形状设计的可扩展梯度增强人工神经网络》，《结构与多学科优化》61 (4) (2020) 1363–1376。 doi:10.1007/s00158-020-02488-5.[6]J. Li、M. Zhang，《基于数据的方法：机翼形状设计优化》，《航空航天科学与技术》112 (2021) 106639。 doi:10.1016/j.ast.2021.106639。

[7] H. Chen、L. He、W. Qian、S. Wang, 《使用卷积神经网络预测翼型的多个气动系数》, Symmetry 12 (4) (2020) 544。[8]Y. Zhang、W. J. Sung、D. N. Mavris, 《卷积神经网络在预测翼型升力系数中的应用》, 载于: 2018 年 AIAA/ASCE/AHS/ASC 结构、结构动力学与材料会议, 2018, 第 1903 页。[9] W. Peng、Y. Zhang、E. Laurendeau、M. C. Desmarais, 《利用神经网络学习空气动力学》, Scientific Reports 12 (1) (2022) 6779。doi:10.1038/s41598-022-10737-4.[10] J. Li、X. Du、J. R. R. A. Martins, 《机器学习在气动外形优化中的应用》, arXiv:2202.07141 [physics]ArXiv: 2202.07141（2022 年 2 月）。[11] X. Guo、W. Li、F. Iorio, 《用于定常流近似的卷积神经网络》, 载于: 第 22 届 ACM SIGKDD 国际知识发现与数据挖掘会议论文集, KDD '16, 计算机协会, 纽约, 美国, 2016, 第 481–490 页。
doi:10.1145/2939672.2939738。网址
https://doi.org/10.1145/2939672.2939738[12] N. Thuerey、K. Weißenow、L. Prantl、X. Hu, 《翼型流动雷诺平均纳维–斯托克斯模拟的深度学习方法》, AIAA Journal 58 (1) (2020) 25–36。
doi:10.2514/1.J058291.[13] H. Wu、X. Liu、W. An、S. Chen、H. Lyu, 《一种用于高效、准确评估超临界翼型流场的深度学习方法》, 《计算机与流体》198 (2020) 104393。 doi:10.1016/j.compfluid.2019.104393。[14]D. Chen、X. Gao、C. Xu、S. Chen、J. Fang、Z. Wang、Z. Wang, 《Flowgan: 一种用于不同条件下流场预测的条件生成对抗网络》, 载于: 2020 年 IEEE 第 32 届人工智能工具国际会议（ICTAI）, 2020, 第 315–322 页。doi:10.1109/ICTAI50040.2020.00057。

[15]C. Duru, H. Alemdar, O. U. Baran, CNNFOIL：用于翼型周围压力场的卷积编码器—解码器建模，《Neural Computing and Applications》33 (12) (2021) 6835–6849。doi:10.1007/s00521-020-05461-x。[16] L. Chen, N. Thuerey，面向翼型可压缩流高准确度深度学习推理，《计算机与流体》250 (2023) 105707。
doi:https://doi.org/10.1016/j.compfluid.2022.105707。[17] V. Sekar, Q. Jiang, C. Shu, B. C. Khoo，采用深度学习方法快速预测翼型周围流场，《流体物理学》31 (5) (2019) 057103。[18] J. Wang, C. He, R. Li, H. Chen, C. Zhai, M. Zhang，基于变分自编码器的深度学习框架预测超临界翼型流场，《流体物理学》33 (8) (2021) 086108。
doi:10.1063/5.0053979。[19] A. I. Roadmap，以人为中心的航空人工智能方法，欧洲航空安全局 1 (2020)。[20] A. Henderson, S. Harbour, K. Cohen，迈向航空航天系统中人工智能（AI）的适航认证，载于：2022 IEEE/AIAA 第41届数字航空电子系统会议（DASC），2022，第1–10页。 doi:10.1109/DASC55683.2022.9925740。[21] M. Drela，《飞行器空气动力学》，MIT出版社，2014。[22]E. L. Houghton, P. W. Carpenter, S. H. Collicott, D. T. Valen- tine，《工程学生空气动力学》，第七版，Butterworth-Heinemann出版社，爱思唯尔旗下品牌，牛津，2017，OCLC：ocn948548390。[23] C. Finn, P. Abbeel, S. Levine，用于深度网络快速适应的模型无关元学习，arXiv:1703。03400 [cs]ArXiv：1703.03400（2017年7月）。[24] D. Ha, A. Dai, Q. V. Le，超网络，arXiv:1609。09106 [cs]ArXiv：1609.09106（2016年12月）。

[25] Z. Yuan, Y. Wang, Y. Qiu, J. Bai, G. Chen，采用卷积神经网络进行翼型气动系数预测，载于：亚太航空航天技术国际研讨会，Springer，2018，第34–46页。[26] X. Du, P. He, J. R. Martins，通过基于神经网络的参数化和代理建模实现快速翼型设计优化，《航空航天科学与技术》113 (2021) 106701。 doi:10.1016/j.ast.2021.106701。[27] M. Sundararajan, A. Taly, Q. Yan，深度网络的公理归因，载于：第34届国际机器学习会议论文集——第70卷，ICML'17，JMLR.org，2017，第3319–3328页。[28]K. Simonyan, A. Vedaldi, A. Zisserman，深入卷积网络：图像分类模型和显著性图的可视化，arXiv:1312。6034 [cs]（2014年4月）。 doi:10.48550/arXiv.1312.6034。URL http://arxiv.org/abs/1312.6034