利用多保真度深度迁移学习尾流模型加速风电场偏航与布局优化

Sо克拉蒂斯·阿纳格诺斯托普洛斯*[1, 2]，Jens Bauer[1], Mariana C. A. Clare[1,3], 和 Matthew D. Piggott[1]

[1]伦敦帝国理工学院地球科学与工程系，英国[2]洛桑联邦理工学院机械工程系，
瑞士洛桑[3]欧洲中期天气预报中心，德国波恩

2023年3月30日

arXiv:2303.16274v1 [cs.LG] 28 Mar 2023

摘要

风电场建模领域近年来受到越来越多的关注，人们开发了众多解析方法和基于计算的方法，以提升风电场效率并最大限度地提高电力生产。在本研究中，我们提出了全新的机器学习（ML）框架 WakeNet。该框架能够在广泛的偏航角、风速和湍流强度（TI）范围内，重现轮毂高度处的通用二维风机尾流速度场；与采用先进风电场建模软件 FLORIS 计算得到的解相比，其平均准确率达到 99.8%。由于生成足量的高保真度数据用于网络训练可能成本过高，我们还研究了多保真度迁移学习的应用。具体而言，我们利用低保真度高斯尾流模型对网络进行预训练，再通过微调获得针对中保真度 Curl 尾流模型的准确尾流结果。通过功率增益热图，我们验证了 WakeNet 在各种尾流引导控制和布局优化场景中的稳健性与整体性能；其获得的功率至少达到直接使用 FLORIS 进行优化所得功率的 90%。我们还证明，使用 Curl 模型时，WakeNet 能够取得与 FLORIS 相近的功率增益，而速度快两个数量级（例如，每个优化情形仅需 10 分钟，而 FLORIS 需要 36 小时）。我们预计，使用高保真度计算流体力学（CFD）数据集训练后的 WakeNet，其尾流评估时间也会相近，从而进一步提升计算时间收益。这些令人鼓舞的结果表明，借助机器学习工具进行通用尾流建模，能够达到足够高的准确度，支持主动偏航与布局优化，同时以极低的计算成本生成真实可行的优化配置，因此能够实现实时主动偏航控制以及不确定性下的稳健优化。

***Key*词语** 尾流建模、深度学习、迁移学习、多保真度、风电场优化

1 引言

目前，可再生能源约占全球能源生产总量的 26% [1]。然而，为了在 2050 年前实现净零排放目标，全球可再生能源发电装机容量必须迅速增长。具体而言，国际能源署（IEA）估计，为实现净零排放目标，到 2030 年之前，每年必须向全球电网新增 390 GW 风电装机容量 [2]。作为参考，在创纪录的 2020 年，全球电网新增风电装机容量不足 100 GW。因此，要实现这些风能目标，我们不仅需要建设新的风电场，还要提高现有风电场的效率。上游风力涡轮机产生的尾流会降低风速并增加湍流强度，从而显著降低下游风力机的电力生产。在整个风电场范围内，这种影响可能使年发电量减少约 20% [3], ，造成重大经济损失 [4]。

近年来，人们开展了大量工作来对风机尾流进行建模，以优化风电场配置，并通过尾流偏转提高现有风电场的效率。尾流偏转是指使上游风力机与风向错开（通过改变偏航角），从而将湍流尾流引离下游风力机的过程。研究表明，这可使风电场整体功率增益最高达到 7% [5]。目前存在多种用于高效尾流建模的解析模型，包括所谓的 Larsen [6], 、Jensen [7], 、Curl [8] 和高斯 [9] 模型；这些模型已被集成到 FLORIS（稳态流动偏转与诱导）软件包等工具中 [10]。FLORIS 计算

*通讯作者，电子邮箱：sokratis.anagnostopoulos19@imperial.ac.uk

风电场中的稳态尾流，其所采用的流动物理过程描述高度简化，并广泛用于尾流偏转和风电场优化研究 [, 例如 11, 12, 13]。研究表明，解析模型得出的风电功率输出与雷诺平均纳维–斯托克斯方程（RANS） [14] 和大涡模拟（LES） [9] 等高保真数值模型的结果相对吻合（平均绝对误差最低为 10–16%），而这些数值模型的执行速度要慢几个数量级。尽管解析模型无法详细呈现风机速度亏损，但实践人员通常会在准确性上做出一定妥协，以获得更实际的计算成本。在布局优化中尤其如此，因为模型需要执行大量次；对于尾流偏转而言更是如此，因为要取得最佳结果，最好能够实时执行这一过程。

过去二十年间，中央处理器和GPU架构的指数级发展，使得人们有可能使用神经网络预测尾流，而不再依赖更为传统的解析模型或基于数值计算的模型。这是运用机器学习技术优化和控制风电场风力发电这一更广泛趋势的一部分 [15]。经过高保真数据训练的合适神经网络有望在数秒内给出可靠结果，预测风电场的流动特性；若采用其他方法，则需要高出几个数量级的计算时间。在我们的研究中，我们使用全连接神经网络（FCNN）和卷积神经网络（CNN）对风机尾流进行建模。此前，研究人员已成功使用全连接神经网络来表征尾流：通过大量RANS模拟输出构成的训练数据集，生成风速和湍流强度（TI）各异的单排风力涡轮机三维尾流剖面 [16], ；通过对解析Jensen模型的尾流进行训练，优化风电场布局 [17] ；以及基于偏航、风速和湍流可变时的广义输出优化风电场 [18]。然而，尾流表征也可以视为图像生成问题，因此在某些情况下，卷积神经网络可能更为适用，因为它们能够准确再现空间特征 [19]。卷积神经网络已成功用于模拟翼型周围的流场 [20], ，也用于生成功率响应面图 [21], ；在后者中，卷积神经网络使用基于高斯解析模型生成的FLORIS输出进行训练。不过，尽管神经网络的预测效率高于传统模型，仍然需要大量训练数据。例如，为了捕捉给定布局在所有入流条件下的电力生产情况，研究人员生成了完整的响应面图，所需训练样本超过一千万个 [21]。因此，在生成合适的训练数据集时，成本与准确性之间仍需权衡。近期还有研究探讨了使用多保真尾流模型来缩短风机尾流评估所需的计算时间 [22, 23]。

在这项工作中，我们采用一种结合迁移学习（TL）的新型多保真方法，利用先前网络的已有知识，更高效地训练新网络 [24]，以解决计算成本与高保真精度之间的权衡问题。这种多保真度迁移学习方法已成功用于求解偏微分方程和模拟翼面绕流 [25, 26], ，但据我们所知，这是该方法首次应用于风能优化问题。具体而言，我们首先使用 FLORIS 中简单的高斯解析模型生成的风场输出训练神经网络，然后通过迁移学习使用 FLORIS 中实现的更复杂、计算成本更高的 Curl模型。这样，我们只需进行较少次数的 Curl模型模拟来生成训练数据，从而节省计算时间。为了最大限度地提高风电场的发电量，我们还必须根据风场估算功率输出。这项工作另一项创新之处在于，我们不采用解析或经验近似，而是训练第二个神经网络，预测每台涡轮机的功率和局部湍流强度。我们的高效神经网络框架能够快速评估多种偏航角和风机位置选择，因此可以轻松进行精确优化，以找到可能达到的最佳功率输出。

因此，本研究旨在构建一个具备多保真功能的神经网络框架，用于风机尾流建模，以远低于传统模型的计算成本实现精准的主动偏航控制和布局优化。本文其余部分安排如下：首先介绍用于合成训练数据集的尾流模型，然后定义尾流建模中采用的机器学习方法。接着，我们展示验证所采用方法的结果，并说明该方法在计算效率方面的显著提升，有望助力实现更高效、更通用的尾流优化。

2 生成训练数据

在这项工作中，我们使用风电场仿真与优化软件 FLORIS [27] 生成用于训练机器学习框架的尾流场。在 FLORIS 中，有多个模型可用于模拟尾流；在本研究中，我们使用高斯解析模型 [9] 和 Curl模型 [8]生成训练数据。

2.1 高斯解析模型

高斯解析模型基于质量守恒和动量守恒原理，并假设尾流亏损服从正态分布 [9]。归一化尾流亏损表示为

$$\frac{\Delta u(x,y,z)}{u_0} = \left(1 - \sqrt{1 - \frac{C_t}{8K}}\right) \exp\left(-\frac{1}{2K}\left(\left(\frac{z - z_h}{d_0}\right)^2 + \left(\frac{y}{d_0}\right)^2\right)\right), \tag{1}$$

其中， $\Delta u(x,\ y,\ z)$表示风速尾流亏损， u_0 表示自由来流速度， C_t 表示推力系数， z_h 表示轮毂高度， d_0 表示转子直径，并且

$$K = \left(k^* \frac{x}{d_0} + \epsilon\right)^2, \tag{2}$$

其中， k^* 定义了根据实验和大涡模拟数据确定的尾流扩展， ϵ 表示转子处的质量流量亏损率。

2.2 Curl模型

Curl模型也包含在FLORIS中，其复杂度和计算开销均高于高斯解析模型。该模型首先通过考虑流向上的雷诺平均纳维–斯托克斯（RANS）方程推导得出，

$$u\frac{\partial u}{\partial x} + v\frac{\partial u}{\partial y} + w\frac{\partial u}{\partial z} = -\frac{1}{\rho}\frac{\partial p}{\partial x} + \nu_{\text{eff}}\left(\frac{\partial^2 u}{\partial x^2} + \frac{\partial^2 u}{\partial y^2} + \frac{\partial^2 u}{\partial z^2}\right), \tag{3}$$

其中，所有变量均为时间平均值， u 表示流向速度， v 表示时间平均展向速度， w 表示壁法向速度， p 表示压力， ρ 表示流体密度， ν_{eff} 表示有效黏度。随后将速度分解为基准分量和扰动，即 $u = U + u'$，其中$(\cdot)'$ 表示围绕基准解分量的扰动，该分量以大写字母表示。线性化后得到

$$U\frac{\partial u'}{\partial x} + V\frac{\partial (U+u')}{\partial y} + W\frac{\partial (U+u')}{\partial z} = -\frac{1}{\rho}\frac{\partial p}{\partial x} + \nu_{\text{eff}}\left(\frac{\partial^2 u'}{\partial x^2} + \frac{\partial^2 (U+u')}{\partial y^2} + \frac{\partial^2 (U+u')}{\partial z^2}\right), \tag{4}$$

并进行各种简化，包括假设压力梯度为零（详见 [8] ），由此得到最终的简化方程，

$$U\frac{\partial u'}{\partial x} + V\frac{\partial u'}{\partial y} + W\frac{\partial (U+u')}{\partial z} = \nu_{\text{eff}}\left(\frac{\partial^2 u'}{\partial x^2} + \frac{\partial^2 u'}{\partial y^2} + \frac{\partial^2 u'}{\partial z^2}\right). \tag{5}$$

Curl模型通过求解后一个方程来确定尾流亏损。

2.3 数据集

核心尾流预测机器学习模块的训练过程基于一个数据集，其中包含使用高斯模型生成的 2000 个尾流，以及使用Curl模型生成的 2000 个尾流。初始风速、湍流强度（TI）和偏航角的范围分别为 [3, 15] m/s、 [0.01、0.2] 和 [-35, 35] 度。初始风速范围依据 NREL 5 MW风力涡轮机的功率曲线确定，其运行下限为 3 m/s；当风速超过 12 m/s 时，偏航优化几乎无法带来进一步的功率增益 [28]。湍流强度的限值依据测量值确定 [29]。采用此方法生成的尾流示例见图 1。数据集中的 2000 个尾流全部用于模型训练，另有 200 个不同的尾流用作验证集。

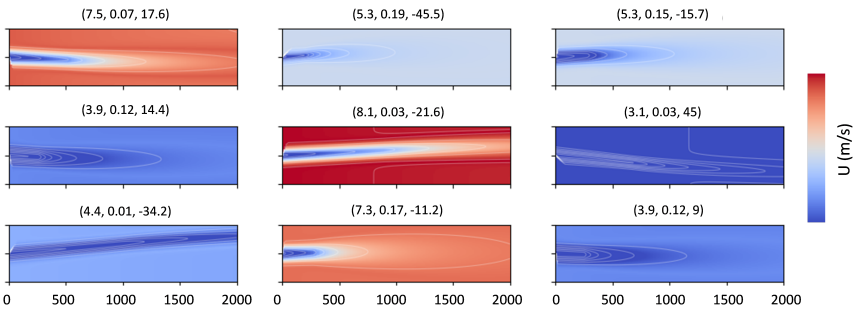

图 1：来自 2000 年尾流数据集的示意性高斯尾流及其对应的输入向量（风速、湍流强度、偏航角）。

3 神经网络方法

在本研究中，我们介绍了一种名为 $WakeNet$的新型机器学习框架，它拓展了我们先前的模型 [18]，旨在模拟用于偏航与布局优化的多保真度尾流效应。$WakeNet$ 由三个核心神经网络模块组成：深度解码器网络（DDN）和卷积神经网络（CNN），二者经过训练，可针对给定的涡轮机重现下游尾流剖面；此外还包括全连接神经网络（FCCNs），用于预测局部湍流强度（TI）和发电功率。代码可在 https://github.com/soanagno/wakenet 获取。

3.1 尾流剖面

3.1.1 深度解码器网络（DDN）

WakeNet 的第一个组件是全连接 DDN。其架构如图 2 所示，由至少两个隐藏层组成，每层含有 200 个神经元，具体数量取决于尾流模型；网络的输出是一个 $m \times n$ 像素网格，用于表示尾流的下游速度场。网络的输入则是一个由三个尾流参数构成的向量，即自由来流风速、TI 和涡轮机的偏航角，这些参数经过均值/标准差归一化处理。此外，我们在每个隐藏层之后都应用了批归一化层，因为以这种方式对训练批次进行重新归一化，能够显著提升训练后网络的性能 [30]。对于激活函数，前两层使用双曲正切函数，输出层则使用线性激活函数。

DDN 使用来自三维 FLORIS 尾流输出的二维水平切片进行训练（生成这些输出的方法详见第 2 节）。这样做的优势在于能够显著加快模型训练速度。此外，由于训练数据来自 FLORIS，而 FLORIS 会隐式考虑海面/陆地表面对大气边界层的影响，因此尽管输入是二维切片，输出层仍包含场址速度边界层的信息。

我们进一步注意到，FLORIS 的默认分辨率为 200×200 网格，因此我们采用该分辨率作为 DDN 的输出分辨率。不过，对于更高的分辨率需求，用户可以在训练模型之前指定所需的分辨率，模型也将生成具有相同分辨率的解析尾流数据集。

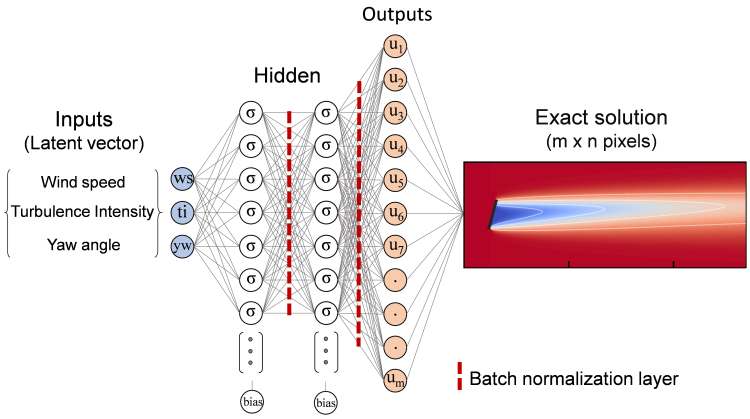

图 2：WakeNet 模块的深度解码器网络（DDN）架构。尾流参数的潜向量被解码为下游速度场。

3.1.2 卷积神经网络（CNN）

除 DDN 外，WakeNet框架还采用了 CNN 架构，也可用于生成二维尾流速度场。CNN 由全连接层和反卷积层组合而成，用于重建单台风力涡轮机周围的流场（图3.1.2）。第一层为全连接层，其输入是涡轮机在轮毂高度处的风速、湍流强度（TI）和偏航角。该层的输出随后被重塑为一个 3×3 数组，并传递至反卷积层。共有六个反卷积层，每层均由带泄漏的 ReLU 激活的 ConvTranspose2d [31] 组成，后接批归一化。CNN 模型的输出是一个包含 200×200 像素的二维数组，用于重建与 DDN 具有相同尺寸的流场。像素数量由网络架构和训练数据决定，因此可以轻松调整。需要指出的是，所采用的 CNN 架构是通过超参数搜索确定的，在搜索过程中测试了不同的层配置。

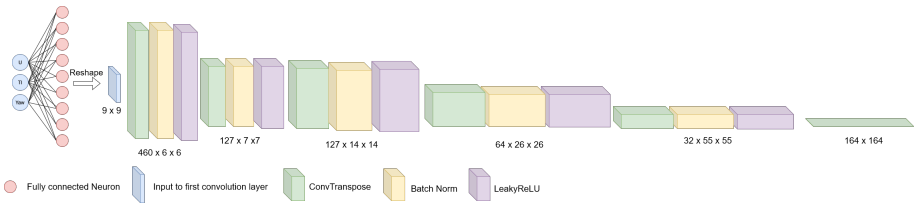

图3：卷积神经网络（CNN）架构。

3.1.3 尾流叠加

上述神经网络提供了一种预测尾流的方法。大多数“解析”尾流模型都采用一种独立的方法，对单个尾流进行叠加，以模拟由多台风力涡轮机构成的阵列，以及它们之间的相互作用 [32, 33]。在本研究中，采用基于平方和模型（SOS）的叠加算法，对生成的多个单个尾流进行组合。通过一种近似方法计算每台涡轮机轮毂处的均匀速度，从而对叠加过程进行修正。最终区域表示构成所研究风电场的各个单个尾流的拼合结果。SOS 模型的形式如下：

$$u_i = \left(1 - \sqrt{\sum_{j=0}^{n}\left(1 - \frac{u_{i,j}}{u_{\mathrm{hub},i}}\right)^2}\right) u_\infty, \tag{6}$$

其中， u_i 是涡轮机 i处组合尾流的风速， $u_{i,\ j}$ 是涡轮机 i 处受涡轮机 j产生的尾流影响的风速。$u_{\mathrm{hub},\ i}$ 是涡轮机 j 处的轮毂风速， n 是影响该位置的尾流数量， u_∞ 是风电场入口处的风速。

3.2 TI和功率预测网络

对于 WakeNet 框架的最终组成部分，我们根据第 3.1 节生成的流场预测功率和湍流强度（TI）。在优化模型 FLORIS 中，风力涡轮机产生的功率根据三维流场计算得出。然而，上述 DDN 和 CNN 生成的是风场的二维水平切片，这意味着需要利用二维数据预测三维风力涡轮机产生的功率。为解决这一问题，我们训练了一个全连接神经网络（FCNN），根据涡轮机上游水平线上的风速预测风力涡轮机的功率输出（图4）。由于湍流尾流的影响，风电场内的流场湍流强度会发生变化。因此，我们使用第二个全连接神经网络（FCNN）预测风力涡轮机处的局部湍流强度。这样，通过这些全连接神经网络（FCNN），即可从二维流场推断三维功率和湍流强度（TI）数据。湍流强度和功率预测全连接神经网络（FCNN）的输入为涡轮机上游 50 米处水平线上的风速、来流湍流强度和涡轮机偏航角。风速线与涡轮机转子投影面积平行，并沿叶片的整个直径延伸。这两个全连接神经网络（FCNN）分别使用 WakeNet 生成的风速以及相应的 FLORIS 功率输出或局部湍流强度进行训练。训练数据由四个示例风电场生成，每个风电场包含六台风力涡轮机。功率和局部湍流强度通过 FLORIS 根据三维流场计算得出，而提取的流动数据来自二维切片。

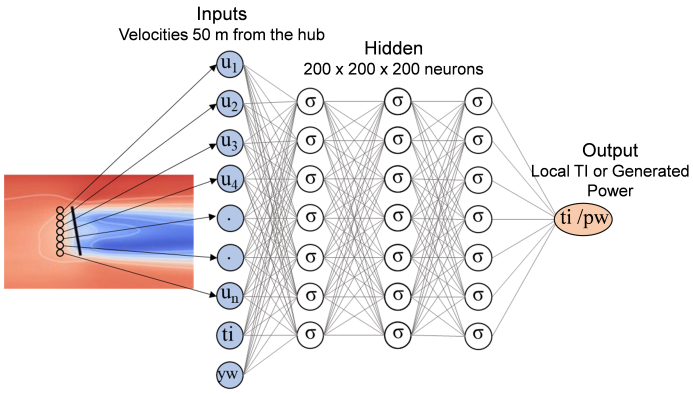

图4：TI和功率预测器（FCNN）架构。

3.3 训练

对于 WakeNet框架中使用的所有神经网络，我们采用通过最小化均方误差（MSE）函数进行训练的标准方法，并使用 Adam优化器 [30] 优化该损失函数。训练在 Nvidia GeForce RTX 3060 上进行，根据尾流数据集的大小，所需时间为 10 到 30 分钟不等。

训练神经网络时，可以调整许多参数以优化训练。我们首先考虑小批量的大小。它会将训练数据集划分为若干小批次，供优化器在每个反向传播步骤中使用。图5显示，小批量大小设为完整数据集的 1/4 时，表现优于使用完整数据集；所需训练轮次更少（分别为 2000 轮和 500 轮），同时训练准确率和验证准确率更高。

另一个可以优化的参数是优化器的学习率。较小的学习率可能需要更多训练轮次，而较大的学习率则可能导致错过最优解。DDN 和 CNN 的最佳学习率均为 0.01。功率预测网络在训练 150 轮时的最佳学习率为 0.003；TI预测网络在训练 80 轮时的最佳学习率为 0.0065。对于湍流强度和功率预测网络，如果验证数据集上的损失在 15 个步骤后仍未下降，则使用学习率调度器将学习率降低至原来的 0.8 倍。这有助于进一步降低验证集和测试集上的误差。

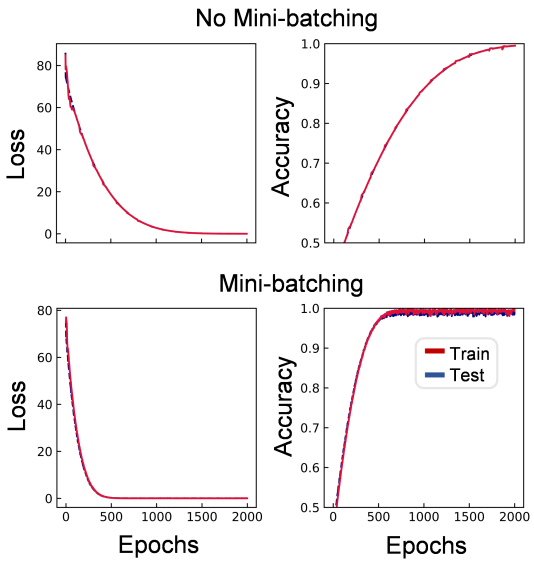

图5：采用和不采用小批量训练时的损失/准确率曲线。

3.4 多保真度迁移学习

本研究的最终目标是创建一个可部署于任何风电场场址的框架，以快速、准确地生成涡轮机偏航设定的优化预测。最终训练所用尾流模型的保真度越高，预测就越准确。然而，针对任意涡轮机类型生成包含大量（至少2000个尾流）高保真度计算流体力学（CFD）结果的尾流数据集并不可行，因为这需要巨大的计算资源。本研究展示了在Curl模型（作为高保真度模型）与高斯尾流模型（计算成本较低的模型）之间进行多保真度迁移学习的能力。

迁移学习模型着重于利用在某一问题的训练过程中获得的已有知识，并将其应用于相似问题。这项技术的应用之一是对预训练神经网络进行微调，以便在数据集有限时仍能得出准确结果。本研究的重点是将低保真度低计算成本尾流模型（如高斯模型）中的知识迁移到保真度更高的 Curl模型中，如图6所示。为进行迁移学习，首先使用高斯模型生成的包含2000个尾流的数据集训练 WakeNet。随后将 DNN 的前两层“冻结”，即在训练过程中，其权重不会通过反向传播算法发生变化；最后一层则根据 Curl数据集所包含的新信息进行训练。

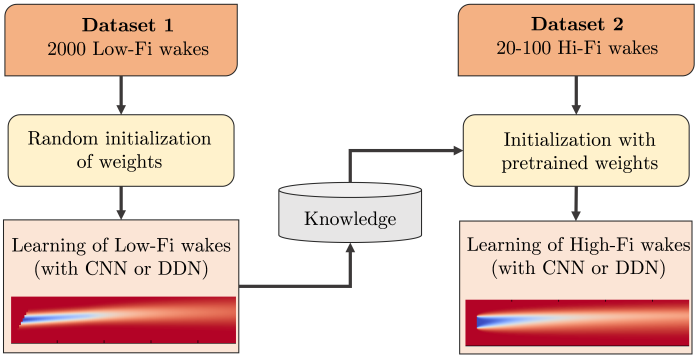

图6：多保真度迁移学习流程图。

4 结果

为展示 WakeNet 的能力，本文考察了若干具有代表性的单尾流和多尾流案例。采用 FLORIS 与各神经网络子模块之间的平均绝对误差（%）这一指标，评估尾流剖面的计算精度。

4.1 尾流场比较

图7和图8分别展示了单涡轮机和多涡轮机风电场的代表性案例。左列展示的是使用包含2000个高斯尾流的数据集训练后得到的评估结果，右列则展示了使用包含2000个Curl尾流的数据集训练后得到的评估结果。图7和图8展示了解析结果与神经网络结果之间的绝对相对误差（%），其计算公式为：

$$\mathrm{Error}_{\%} = \left| \frac{u_{\mathrm{WakeNet}} - u_{\mathrm{FLORIS}}}{u_{\mathrm{stream}}} \right| \times 100. \tag{7}$$

对于单尾流情形（图 7），WakeNet 能够为两种尾流模型（高斯模型和 Curl模型）复现 FLORIS 的精确解：高斯模型的平均误差小于 2%，Curl模型的平均误差小于 1%；同时，沿物理域水平横截面的三个 y-截面上的速度剖面与精确截面一致。

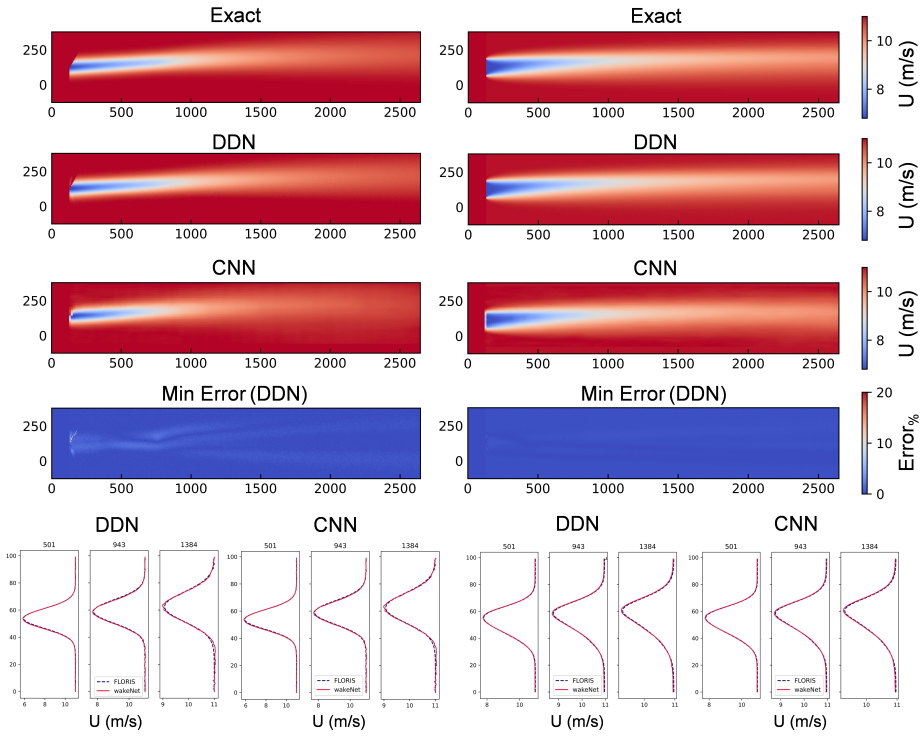

图7：高斯模型（左）和Curl模型（右）的单尾流对比示例。Exact表示使用FLORIS获得的结果。

所选取的多重尾流情形（图 8）用于测试 WakeNet 在高风机偏航设置的密集风电场配置下的性能。正如预期，在尾流速度域的某些区域（图 8c），绝对误差有所增加（最高可达 10%），因为在这种情况下，叠加法也会影响结果。然而，平均绝对误差小于 5%，图 8d 中高斯模型和 Curl 模型的 y-截面总体上吻合良好，仅有少数例外，主要出现在多尾流叠加的区域。

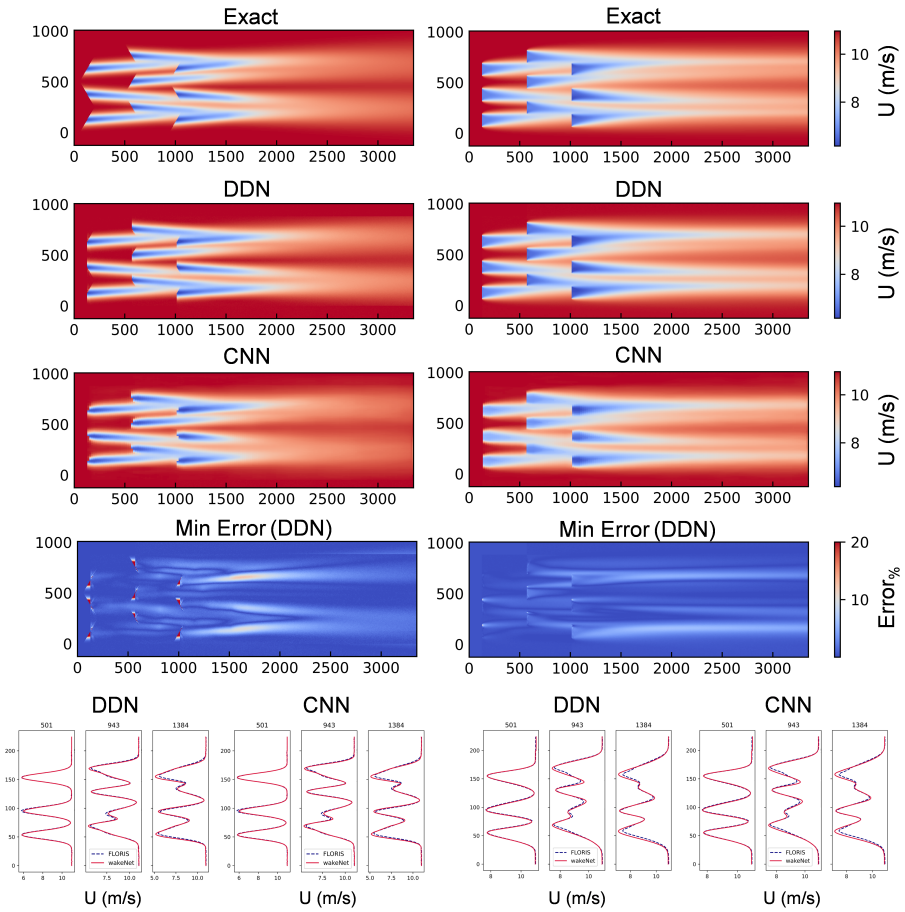

图 8：高斯模型（左）和 Curl 模型（右）的多重尾流对比示例。

4.2 湍流强度和功率网络结果

每台涡轮机产生的功率以及风机轮毂处的局部湍流强度，均使用第 3.2 节所述的全连接神经网络计算。图9(a)展示了 FLORIS 生成的单台涡轮机功率曲线，以及全连接神经网络预测的功率。功率全连接神经网络的平均误差为 1.17%，表明其能够准确预测功率输出。图9(b)对比了全连接神经网络与 FLORIS 对图8所示风电场的功率和局部湍流强度预测结果。即使涡轮机位于上游风机的尾流中，全连接神经网络也能准确预测各台涡轮机产生的功率。测试集上的平均功率百分比误差为 2.8%，全连接神经网络对局部湍流强度的预测在测试数据上的平均误差为 7.6%。对于 200 组随机生成的速度和湍流强度入流条件，图8所示风电场的功率和湍流强度预测平均百分比误差分别为 3.9% 和 8.5%。

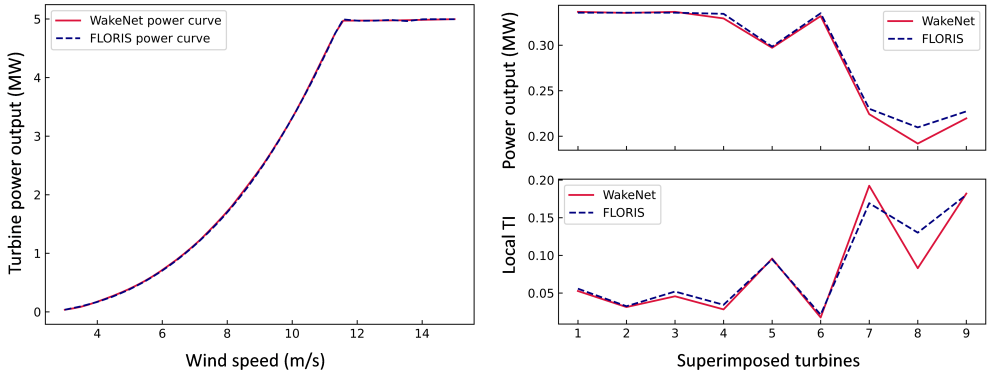

(a) (b)

图9：WakeNet 功率和湍流强度预测与高斯 FLORIS 的比较；（a）风力机功率曲线；（b）根据风力机编号对风电场进行预测（按 x位置升序排列；如果风力涡轮机具有相同的 x位置，则按 y位置升序排列）。

图10展示了对下游湍流强度值波动进行修正的概念，其中四台串联风力机之间的距离极短，仅为 2.5 个风力机直径。未采用湍流强度预测网络的神经网络模型会导致每台风机后的速度亏损出现系统性误差，使最后一次尾流评估中的误差达到 30%（图10(a)）；而在修正后的情况下，湍流强度网络能够将误差维持在恒定水平，低于 3%。

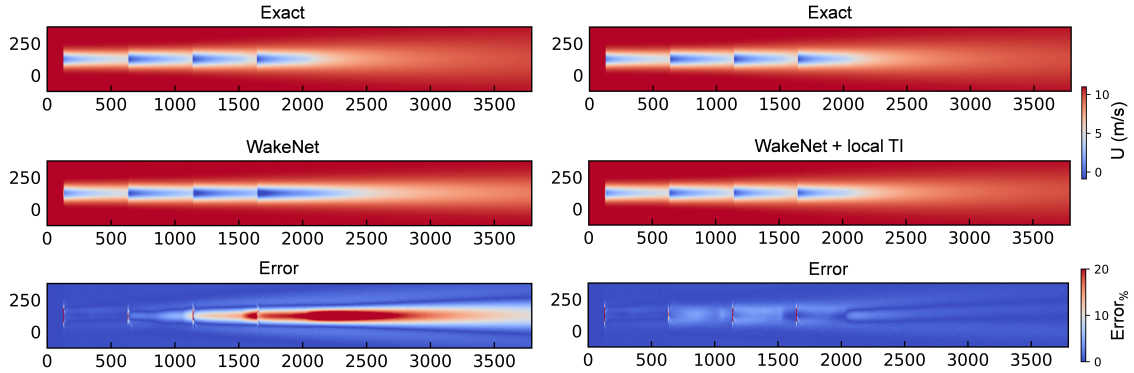

(a) (b)

图10：使用高斯 DDN 对四台串联风力机进行风电场尾流预测，无湍流强度网络（a）和启用湍流强度网络（b）。

最后，图11展示了通过在下游方向上以5D间距布置两台涡轮机并改变其偏航角而生成的功率增益等值线的相关性。在引入湍流强度和功率预测网络之前，WakeNet等值线与FLORIS生成的精确解（为简洁起见未显示）并不匹配；但经过湍流强度和功率网络预测结果的修正后，最大功率值和角相位空间位置均实现了匹配，即在 ∼3.3 MW处，前方和后方风力机的偏航角分别为15度和0度。

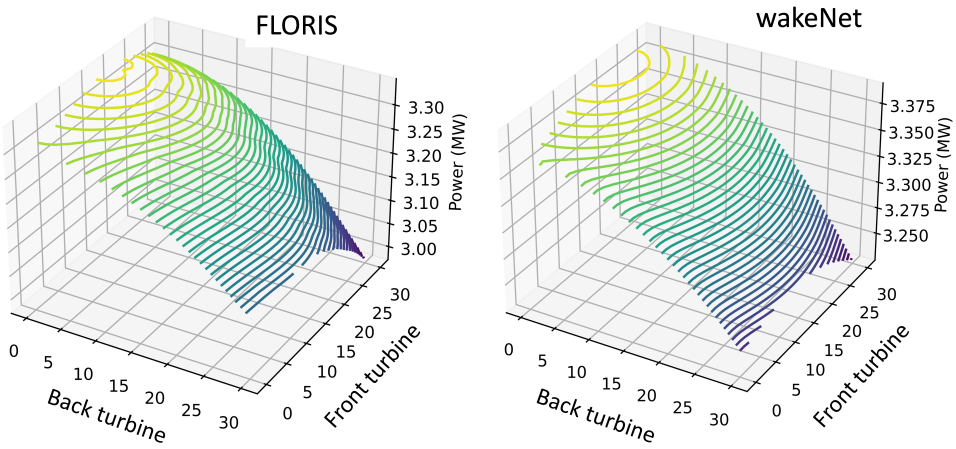

图11：下游方向相距5D的两台涡轮机在偏航角变化时产生的总功率；在高斯数据上训练的神经网络（a）以及使用高斯模型的FLORIS（b）的预测结果。

4.3 多保真度迁移学习尾流结果

图12展示了采用多保真度迁移学习方法的优势，其中比较了不同训练数据集规模对模型准确率的影响，并对比了仅使用Curl数据与采用迁移学习方法的结果。在图12中，每条曲线分别表示在改变Curl数据集规模（从20个尾流增加到100个尾流）的训练过程中所达到的最小损失（图12(a)）或最高准确率（图12(b)）。仅使用100个尾流时，预训练模型的准确率就超过了99.8%（CNN为99.5%，DDN为99.8%）。训练过程中观察到的一个重要特征是，大多数准确率低于99%的训练模型都存在风场噪声或不准确的自由来流速度，而这两种情况都会使所得尾流不适合参与风电场优化。对于涉及生成数千个候选风力涡轮机尾流的遗传优化过程，为使解在合理时间内收敛，准确率至少需要达到99%。如果存在噪声，优化过程可能无法收敛，或者为了获得偏航设置或风力涡轮机布局的最优解，可能需要比FLORIS优化器多得多的迭代次数。最后需要指出的是，在Ryzen 9 5900HX处理器上生成包含2000个尾流的Curl数据集需要超过7小时的计算时间。由于达到99.8%以上的准确率只需要100个尾流，因此使用迁移学习可将计算成本降低20倍。生成至少包含2000个尾流的完整计算流体力学数据集需要数天时间，因此，将计算时间降低一个数量级将显著提升构建基于更高保真度尾流结果的机器学习优化框架的能力。

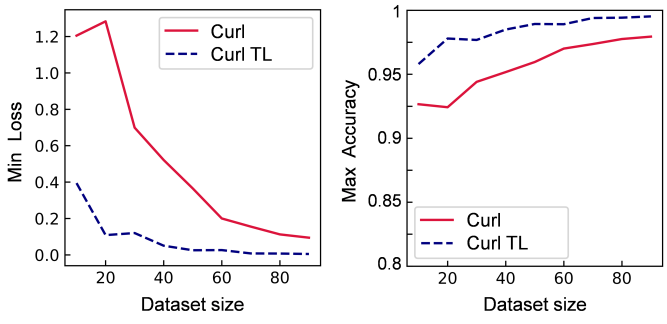

图12：使用Curl模型进行DDN训练时的验证损失和验证准确率图，其中（a）采用迁移学习，（b）未采用迁移学习。

图13定性地展示了迁移学习的优势（其中WakeNet基于包含100个尾流的精简Curl数据集进行训练），并且可以清楚地看出，利用迁移学习后，单风力涡轮机尾流区域的准确性得到了提升。WakeNet迁移学习模型能够更准确地捕捉场中的特征，包括

风机尾流内的速度降低以及自由来流域。此外，不采用迁移学习的WakeNet模型不够准确，无法为风电场总功率评估生成有意义的结果，因此不适用于优化场景。

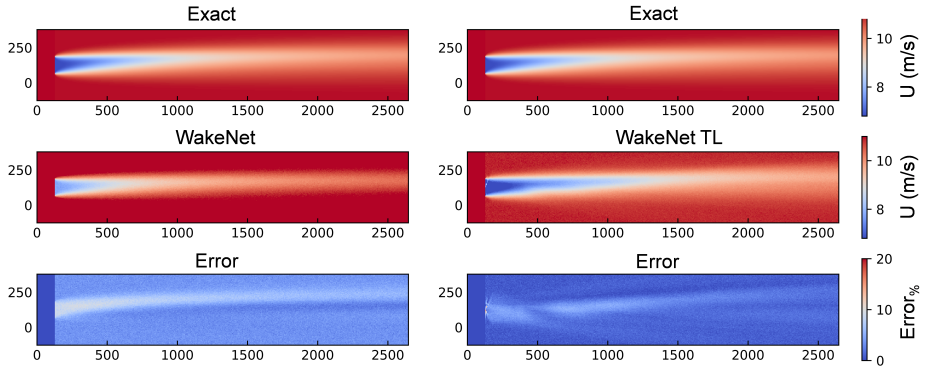

图13：使用仅包含100个尾流的有限Curl数据集进行的示例性尾流对比，展示迁移学习（TL）前（左）和后（右）的效果。

4.4 计算时间缩放

我们进一步测试了 WakeNet 在最多叠加24台风力涡轮机时的计算时间缩放性能。图14(a)展示了高斯模型下 FLORIS 与 WakeNet 的双对数时间对比，图14(b)则展示了 Curl 模型的相同对比。正如预期，在高斯模型下，WakeNet 和 FLORIS 的缩放情况相似，WakeNet 并未带来计算时间收益，因为 FLORIS 和 WakeNet 均能在一秒内计算/评估包含24台风力涡轮机的风电场。然而，对于 Curl 模型，WakeNet 评估尾流场的速度快两个数量级以上（24台风力涡轮机的情况下为0.5秒，而 FLORIS 需要40秒）。与之前一样，每叠加一台风力涡轮机时计算时间的增长率对 WakeNet 和 FLORIS 而言相同。需要指出的是，计算时间包含了计算风电场总功率所需的时间。不过，为此，WakeNet 还会生成二维速度场数组，且无需显著增加计算时间即可轻松将其可视化。FLORIS 不会生成该数组；如果将 FLORIS 中生成二维速度场数组的过程也计入其计算时间，那么计算时间收益将显著提高，即使在高斯尾流的情况下也是如此。

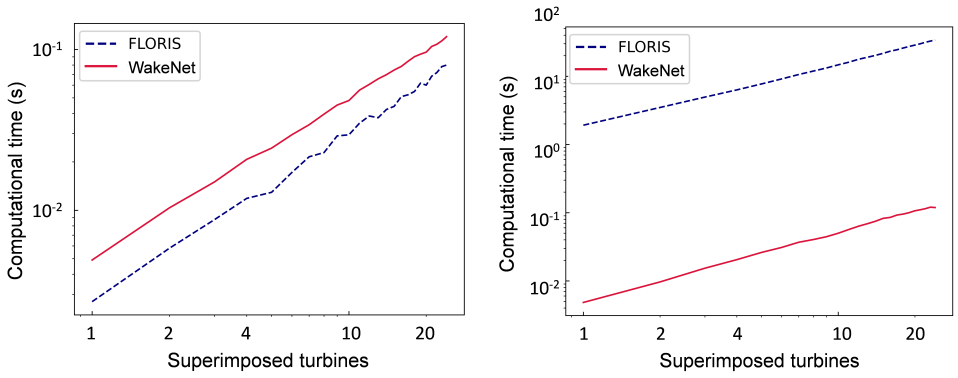

(a) (b)

图 14：使用 Floris 和 WakeNet 对高斯（a）和 Curl（b）模型进行最多 24 台涡轮机模拟时的对数计算时间缩放。

相似的 性能由 CNN 模块实现，因此，出于简化考虑，选择 DNN 模 le
用于 本研究其余部分所呈现的结果。

4.5 优化

本研究中考虑的偏航角和布局优化场景针对两种不同的风电场布局进行，分别为一个6台风机布局（案例 A）和一个密集型15台风机布局（案例 B），如图15所示。本研究使用 SciPy 的 SLSQP优化器 [34] 对风电场产生的总功率进行优化。初始配置的精确

功率输出，以及域内最优偏航设置和最优风力机位置对应的功率输出，始终由 FLORIS 计算，以便比较 WakeNet 与 FLORIS 的性能。

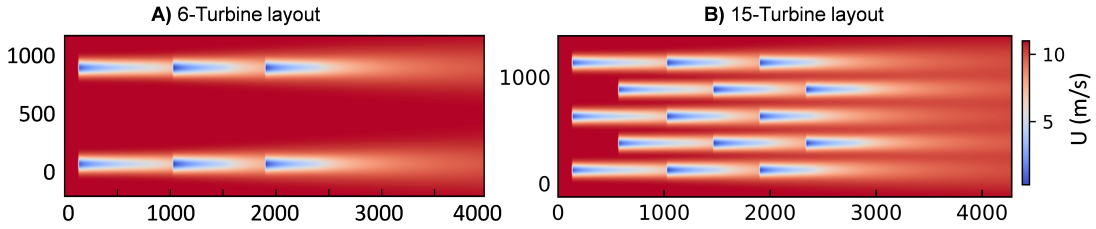

图15：各优化情形所使用的布局。

4.5.1 基于高斯的优化

为评估神经网络获取最优功率增益的能力，图16展示了基于高斯的优化所对应的风电场总功率热图。这些热图可用于比较 FLORIS优化结果（精确值）与 WakeNet 的结果：两者均用于对风电场A和B进行偏航优化，并对风电场A进行布局优化，所涉及的湍流强度和风速值范围各异。从这些热图可以明显看出，潜在功率增益最高的区域位于右下角附近，该区域的特点是湍流强度低、入口风速高。

对于两种偏航情形，WakeNet 优化得出的最优偏航设置可实现至少相当于 FLORIS优化器 90% 的功率增益。对于布局优化情形，WakeNet 的整体表现与 FLORIS 相近，两种优化器生成的功率增益区域都可见一些噪声。此外，正如根据图 14 的时间尺度关系所预期的那样，FLORIS 和 WakeNet 优化器生成每张优化热图的平均计算时间成本处于同一数量级（表1）。

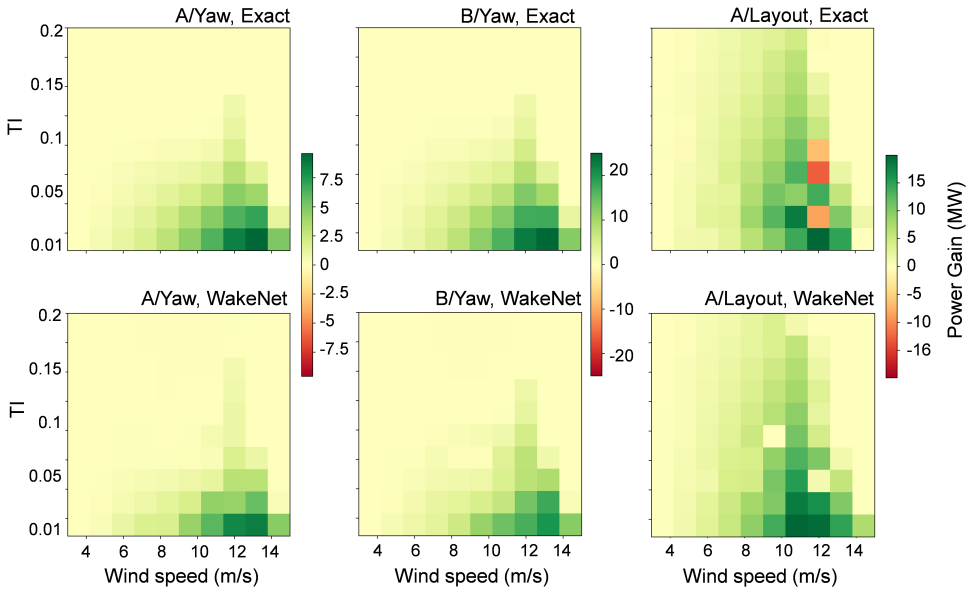

图16：使用基于包含2000个高斯尾流的数据集训练的 WakeNet，对偏航与布局优化的功率增益进行热图比较。

表1：高斯尾流模型的平均优化耗时。

案例/类型 / 模型	A/偏航，平均时间（秒）	B/偏航，平均时间（秒）	A/布局，平均时间（秒）
FLORIS	8	31.5	7.3
WakeNet	5.2	39.5	5

4.5.2 基于 Curl 的优化

基于 Curl 的 WakeNet 用于为布局 A 生成类似的优化热力图。由于 Curl模型的计算需求很高，基于 Curl 的优化仅在基于高斯方法的优化热力图先前确定的高潜在功率增益区域范围内进行。图 17 显示，FLORIS 精确解所得到的优化结果与 WakeNet（基于 2000 个 Curl 尾流训练）和 WakeNet TL（基于 100 个 Curl 尾流训练）均高度相关；这两种神经网络模型给出的优化偏航角均可实现超过精确解潜在功率 90% 的功率。相比之下，未经 TL、基于 100 个尾流训练的 WakeNet 模型只能实现不到 30% 的该功率增益；鉴于其较低的训练准确率以及 4.3 节中的定性结果，这一表现符合预期。

尽管如此，这些结果的重要意义在于相应的计算时间热力图及其时间平均值（见表 2）。对于所展示的热力图，FLORIS 平均需要 25 分钟来完成每项优化（像素），而 WakeNet 平均只需 35 秒。

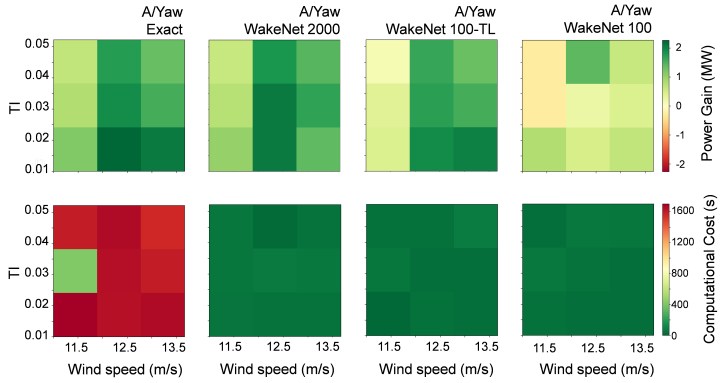

图 17：偏航优化热力图。比较精确解与 WakeNet 在 Curl数据集上的功率增益和计算成本；这些数据集分别包含 2000 个尾流、100 个经迁移学习（TL）处理的尾流，以及 100 个未经迁移学习（TL）处理的尾流。

表 2：Curl 平均偏航优化耗时。

案例/类型 / 模型	平均时间（秒）
FLORIS	1500
WakeNet 100	38
WakeNet 100-TL	32
WakeNet	41

此外，针对图15中的布局 A 和布局 B，在固定风速为 11 m/s、湍流强度为 0.05 的条件下，分别进行了两项示例性布局优化（表 3）。图18展示了 FLORIS 和 WakeNet 优化器得到的最优布局。虽然最优解并不唯一（因此两种优化器得到的收敛布局不同），但采用的策略相似：将风力涡轮机沿下游方向和垂直方向分散，以尽量减少阻塞损失。根据表 3 中的优化结果，WakeNet 优化器分别获得了 FLORIS 所得潜在功率增益的 4.4% 中的 3.5%，以及 61.28% 中的 60.83%。对于布局 A（图18(a)），WakeNet 在不到一分钟内即可实现这些功率增益，而 FLORIS 则需要两小时。对于布局 B，FLORIS 优化器需要 36 小时，而 WakeNet 优化器仅需 13 分钟。因此，总体计算时间收益超过两个数量级，这与第 4.4 节时间尺度研究中的计算收益一致。需要注意的是，随着风力涡轮机数量增加，尾流相互作用的组合也随之增多，布局优化所需时间会呈指数增长。

总之，我们认为，本文展示的基于 Curl 的优化场景所带来的计算时间收益，是迈向实时偏航优化和更复杂布局优化（例如使用高保真尾流模型进行不确定性下的优化）的重要一步。

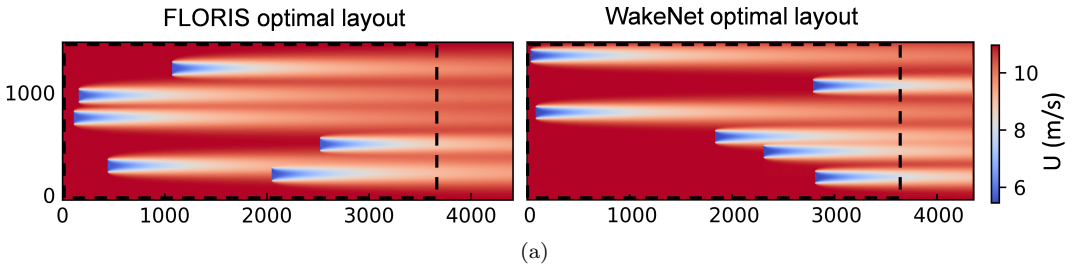

(a)

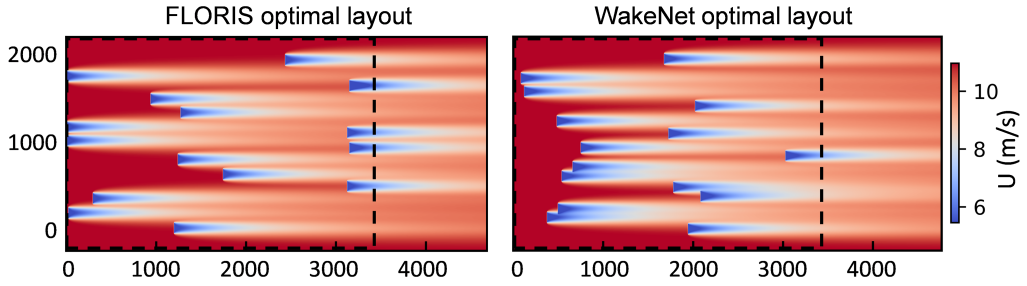

(b)

图18：FLORIS 和 WakeNet 优化器为6台涡轮机（a）和15台风力涡轮机风电场（b）生成的基于Curl的优化布局。虚线表示空间约束。

表 3：Curl布局优化器信息。

案例/模型 Info	A/FLORIS	A/WakeNet	B/FLORIS	B/WakeNet
初始功率（MW）	4.06	4.06	42.2	42.2
功率增益（%）	47.1	46.35	61.28	60.83
计算成本（分钟）	121	0.5	2160	13

5 结论

全新的机器学习框架 WakeNet 能够在广泛的偏航设置、风速和湍流强度范围内，重现轮毂高度处的通用二维涡轮机尾流场；与 FLORIS 中高斯模型或 Curl 模型生成的下游速度场相比，其平均准确率达到 99.8%。WakeNet 采用两个全连接神经网络，根据其二维流场预测近似局部湍流强度和发电功率这两种复杂的三维物理量。这些附加网络能够以 98% 的平均准确率预测局部湍流强度和功率值。构成 WakeNet 的所有机器学习模块均通过多个叠加示例进行了验证。

随着叠加涡轮机数量的增加，WakeNet 的计算成本扩展规律与采用高斯尾流模型的 FLORIS 处于同一数量级。然而，当 WakeNet 使用更复杂的 Curl 尾流模型进行训练时，其计算时间收益比采用 Curl 尾流模型的 FLORIS 高出两个数量级。预计 WakeNet 使用保真度更高的计算流体力学数据集进行训练时，尾流评估时间也会相近，从而进一步提升计算时间收益。这将成为未来研究的课题。此外，通过功率增益热图，验证了 WakeNet 在不同风速和湍流强度下的各种偏航与布局优化场景中的稳健性和整体性能。使用高斯模型训练时，WakeNet 能够复现相似的最优配置（获得至少相当于 FLORIS 优化所带来功率增益 90% 的功率增益），且计算成本处于相近的数量级，这符合预期。然而，对于 Curl 模型，WakeNet 平均而言能够以比 FLORIS 快至少两个数量级的速度实现相近的功率增益，这一点也得到了计算成本扩展规律结果的印证。

最后，采用多保真度迁移学习，对在低保真度尾流模型上预训练的网络权重进行微调（包含 2000 个尾流的高斯数据集），利用有限的数据集（包含 100 个尾流的 Curl 数据集）获得高保真度尾流模型的准确尾流结果。训练后的迁移学习网络已用于初步的偏航与布局优化，其寻找最优配置的速度平均比 FLORIS 快两个数量级，将原本需要 1–2 小时的优化任务缩短至几秒。

这些令人振奋的结果表明，借助机器学习工具进行通用尾流建模可以达到足够高的精度，

从而有助于应用于主动偏航和复杂布局优化。此外，神经网络模型可基于高保真尾流模型进行训练，以极少的计算时间生成更逼真的优化配置，使主动偏航优化能够用于实时应用。多保真迁移学习技术有助于在高保真数据集有限的情况下，获得类似的流动和优化结果；如果求解时间不允许构建大型数据集（例如，使用大涡模拟求解器生成 2000 个尾流，计算成本极高），这类技术就尤为实用。所提出的方法有望以最低的安装/运行成本，最大限度地提高风电场功率增益。未来计划实施的内容包括：增加风向切变和风向等网络输入预测变量；引入基于计算流体力学数据集的更高保真度迁移学习步骤，以进一步改善逼真的尾流近似；在真实风电场场景中测试我们的框架；并行计算前向评估，以加快优化速度。

参考文献

[1] REN21. *Renewables 2021 Global Status Report*. REN21秘书处，法国巴黎，2021年。

[2] 国际能源署。 *Net Zero by 2050. A Roadmap for the Global Energy Sector*。2021年。

[3] Rebecca Jane Barthelmie、K Hansen、Sten Tronæs Frandsen、Ole Rathmann、JG Schepers、W Schlez、J Phillips、K Rados、A Zervos、ESa Politis 等。海上大型风电场中的流动和风力涡轮机尾流建模与测量。 *Wind Energy: An International Journal for Progress and Applications in Wind Power Conversion Technology* 12 5 431 444, 2009 ,

（）：–。[4] JK Lundquist、KK DuVivier、D Kaffine 和 JM Tomaszewski。无协调风能开发引发的风力涡轮机尾流效应的成本与后果。 *Nature Energy*，4(1):26–34，2019。[5] Bingzheng Dou、Timing Qu、Liping Lei 和 Pan Zeng。使用三维偏航尾流模型优化风电场中的风力涡轮机偏航角。 *Energy*，209:118415，2020。[6] Gunner C Larsen。一个简单的定常半解析尾流模型。 *Risø National Laboratory for Sustainable Energy Technical University of Denmark: Roskilde Denmark* 2009 , , , 。

[7] Niels Otto Jensen。 *A note on wind generator interaction*，第 2411 卷。Citeseer，1983。[8] Luis A Mart´ınez-Tossas、Jennifer Annoni、Paul A Fleming 和 Matthew J Churchfield。卷曲尾流的空气动力学：面向流动控制的简化模型。 *Wind Energy Science*，4(1):127–138，2019。[9] Majid Bastankhah 和 Fernando Port´e-Agel。风力涡轮机尾流的新解析模型。 *Renewable energy* 70 116 123, 2014

，：–。[10] Pieter MO Gebraad、FW Teeuwisse、JW Van Wingerden、Paul A Fleming、SD Ruben、JR Marden 和 LY Pao。通过偏航控制实现风电场功率优化：采用尾流效应参数化模型的计算流体力学模拟研究。 *Wind Energy*，19(1):95–114，2016。[11] Antonio Cioffi、Claudia Muscari、Paolo Schito 和 Alberto Zasso。在 OpenFAST 中实现的稳态风电场尾流模型。 *Energies*，13(23):6158，2020。[12] Xiaoxia Gao、Yue Li、Fei Zhao 和 Haiying Sun。不同尾流模型在风电场布局优化中的精度比较。 *Energy Exploration & Exploitation*，38(5):1725–1741，2020。[13] Eric Simley、David Bensason、Owen Roberts、Paul Fleming、Mithu Debnath、Jennifer King、Christopher Bay 和 Rafael Mudafort。评估尾流偏转在美国陆上风电场中的潜力。*Journal of Renewable and Sustainable Energy*，13，2021。[14] Luis A Mart´ınez-Tossas、Jennifer King、Eliot Quon、Christopher J Bay、Rafael Mudafort、Nicholas Hamilton、Michael F Howland 和 Paul A Fleming。卷曲尾流模型：用于风电场流动的三维超快速稳态尾流求解器。 *Wind Energy Science*，6(2):555–570，2021。[15] Yirui Wang、Yang Yu、Shuyang Cao、Xingyi Zhang 和 Shangce Gao。人工智能算法在风电场中的应用综述。 *Artificial Intelligence Review*，53(5):3447–3500，2020。[16] Zilong Ti、Xiao Wei Deng 和 Hongxing Yang。使用机器学习进行风力涡轮机尾流建模。*Applied Energy*，257:114025，2020。[17] Martina Fischetti 和 Marco Fraccaro。机器学习结合数学优化以预测海上风电场的最优产出。 *Computers & Operations Research*，106:289–297，2019。[18] S Anagnostopoulos 和 MD Piggott。使用深度前馈神经网络进行风电场尾流建模，以实现主动偏航控制和布局优化。载于 *Journal of Physics: Conference Series*，第 2151 卷，第 012011 页。IOP Publishing，2022。

[19] Sheng-Yu Wang、Oliver Wang、Richard Zhang、Andrew Owens 和 Alexei A Efros。CNN生成图像出人意料地容易被识别……目前如此。载于 *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* 8695 8704, 2020 ，第 – 页。[20] Haizhou Wu 、 Xuejun Liu 、 Wei An 、 Songcan Chen 和 Hongqiang Lyu。使用深度学习高效且准确地评估超临界翼型的流场。 *Computers & Fluids* 198 104393, ， ： 。 2020
[21] Dylan Harrison-Atlas、Ryan N King 和 Andrew Glaws。机器学习助力开展全国范围的风电场控制评估，并对土地利用产生影响。 *Wind Energy*，2021。[22] Rui Li、Jincheng Zhang 和 Xiaowei Zhao。基于新型超保真网络的风电场尾流多保真建模。 *Energy Conversion and Management*，270:116185，2022。[23] Suraj Pawar、Ashesh Sharma、Ganesh Vijayakumar、Chrstopher J. Bay、Shashank Yellapantula 和 Omer San。迈向风力涡轮机尾流的多保真度深度学习。 *Renewable Energy*，200:867–879，2022。[24] Chuanqi Tan、Fuchun Sun、Tao Kong、Wenchang Zhang、Chao Yang 和 Chunfang Liu。深度迁移学习综述。载于 *International conference on artificial neural networks*，第 270–279 页。Springer，2018。[25] Souvik Chakraborty。基于迁移学习的多保真度物理信息深度神经网络。 *Journal of Computational Physics* 426 109942, 2021 ， ： 。

[26] Kohei Harada、Dushhyanth Rajaram 和 Dimitri N Mavris。使用风洞测量研究多保真度物理信息神经网络在跨声速翼型上的应用。载于 *AIAA SCITECH 2022 Forum*，第 0386 页，2022。

[27] NREL Knud A. Kragh 和 Morten H. Hansen。通过改善偏航对准实现功率增益的潜力。 *Wind Energy*，18 6 979 989，2015（）：–。[29] T. J. Chung。 *Computational Fluid Dynamics*。剑桥大学出版社，2002。[30] Diederik P. Kingma 和 Jimmy Ba。Adam：一种随机优化方法，2014。[31] Xavier Glorot、Antoine Bordes 和 Yoshua Bengio。深度稀疏整流神经网络。载于 *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics* 315 323, 2011 ，第– 页。[32] K. Gunn、C. Stock-Williams、M. Burke、R. Willden、C. Vogel、W Hunter、T. Stallard、N. Robinson 和 S. R. Schmidt。单尾流叠加在风电场产能评估中有效性的局限性。 *Journal of Physics: Conference Series* 749 1 012003, 2016 ，

（）： 9月。[33] Christopher R. Vogel 和 Richard H. J. Willden。利用雷诺平均纳维-斯托克斯模拟研究风力涡轮机尾流叠加模型。 *Wind Energy*，23(3):593–607，2020。[34] Pauli Virtanen、Ralf Gommers、Travis E. Oliphant、Matt Haberland、Tyler Reddy、David Cournapeau、Evgeni Burovski、Pearu Peterson、Warren Weckesser、Jonathan Bright、St´efan J. van der Walt、Matthew Brett、Joshua Wilson、K. J arrod Millman、Nikolay Mayorov、Andrew R. J. Nelson、Eric Jones、Robert Kern、Eric Larson、C J Carey、 ̇Ilhan Polat、Yu Feng、Eric W. Moore、Jake VanderPlas、Denis Laxalde、Josef Perktold、Robert Cimrman、Ian Henriksen、E. A. Quintero、Charles R. Harris、Anne M. Archibald、Antˆonio H. Ribeiro、Fabian Pedregosa、Paul van Mulbregt 和 SciPy 1.0贡献者。SciPy 1.0：Python科学计算的基础算法。 *Nature Methods*，17:261–272，2020。