arXiv:2601.02614v1 [physics.plasm-ph] 6 Jan 2026

GKFieldFlow：用于非线性陀螺动理学湍流的时空神经代理模型三维 *U-Net* + 时间卷积网络架构：联合预测场与输运

Arash Ashourvan

Independent Researcher, San Diego, CA, USA

我们介绍了 GKFieldFlow，这是一种用于非线性陀螺动理学湍流的新型三维自回归深度学习代理模型。该模型基于架构 FieldFlow-Net，结合了一个多分辨率三维 U-Net 编码器-解码器，用于处理不断演化的等离子体电势场。扩张时间卷积网络（TCN）负责学习湍流特征随时间的非线性演化。 GKFieldFlow 同时实现以下功能：(i) 直接根据 CGYRO 湍流预测离子和电子能通量以及粒子通量；(ii) 以自回归方式预测未来电势场，并支持指定的空间分辨率。这使模型既能复现瞬时输运，也能复现产生输运的底层时空动力学。

该架构在设计上融入了物理信息：三维卷积保留了陀螺动理学涨落的各向异性几何特征和相位结构，而膨胀时间卷积则捕捉多尺度动力学耦合，例如湍流与带状流相互作用、湍流去相关以及间歇性突发输运。我们完整介绍了数据结构、模型组件，以及各项架构选择背后的依据。

该模型在全部三个输运通道上均实现了高精度，多时间范围推断也保持了鲁棒性。自回归场滚动预测以很高的保真度保留了 CGYRO 非线性状态的谱含量、相位相干性和能量分布，通量预测与 CGYRO 的结果也保持一致，相对误差较小。本研究提出了 GKFieldFlow，将其作为一种数据驱动降阶模型，可联合学习湍流动力学与输运。

I. 引言

理解并预测湍流输运，仍是磁约束聚变研究中的核心挑战。托卡马克等离子体中的小尺度微湍流调节横场热通量和粒子通量，并显著影响宏观约束性能。因此，模拟、预测和控制湍流输运的能力，对于提升预测能力并推动等离子体运行迈向可靠且与反应堆相关的水平至关重要。 [1–3]。

非线性陀螺动理学（GK）模拟能够高保真地预测磁约束聚变等离子体中的微湍流和输运。然而，尽管精度很高，这类模拟仍然需要大量计算资源。一次离子尺度 CGYRO 模拟通常需要数百 GPU 小时才能达到完全饱和的湍流状态；若要扫描平衡剖面、碰撞性、 β或形状参数，所需时间还会更长。对于表现出多尺度湍流的等离子体，挑战则严峻得多，因为长波长离子尺度模会与短波长电子尺度模相互作用。完全解析的多尺度模拟需要同时保留差异巨大的时空尺度，使计算成本增加两到三个数量级 [4–6]。因此，基于非线性 GK 湍流的常规预测建模，对于大多数实验工作流程、情景开发研究和等离子体实时控制应用而言，仍然难以实现。相反，输运代码几乎完全依赖准线性（QL）约化模型（例如 TGLF [7]和 Qua-LiKiz [8] ）进行预测建模；这类模型通过对非线性饱和谱进行简化近似，以低几个数量级的计算成本计算输运通量。

尽管 QL 模型在许多核心等离子体物理状态下展现出出色的预测能力，但众所周知，在强非线性条件或电磁边缘条件下，其精度会下降；这类情况包括具有陡峭梯度的基座区域、强$E\times B$ 剪切、微撕裂湍流，以及多尺度效应或非局域效应显著的物理状态 [9–11]。这些局限表明，业界日益需要新型湍流代理模型，在显著加快推理速度的同时，保留非线性 GK 建模的保真度。

现代机器学习（ML）的兴起为解决这一问题提供了颇具前景的途径。如今，聚变领域已积累了丰富的线性与非线性陀螺动理学模拟档案，涵盖数十年的理论与实验成果。利用这些数据库训练高维神经代理模型，有望大幅加速湍流推断、实现快速剖面预测，并支持 ITER 等装置及未来示范电站的集成建模工作流。然而，如何训练神经网络模拟陀螺动理学湍流丰富、多尺度且各向异性的结构，仍是一项有待解决的挑战。

在这项工作中，我们提出了 GKFieldFlow，这是一种三维时空神经代理模型，直接基于非线性 CGYRO场数据训练，既能演化陀螺动理学湍流结构，也能预测相关输运。该模型通过一种专门设计的架构实现，我们将其称为 FieldFlow-Net：由三维卷积 U-Net 编码器–解码器与扩张时间卷积网络 (TCN) 耦合而成。这些组件共同构成一个双头自回归代理模型，

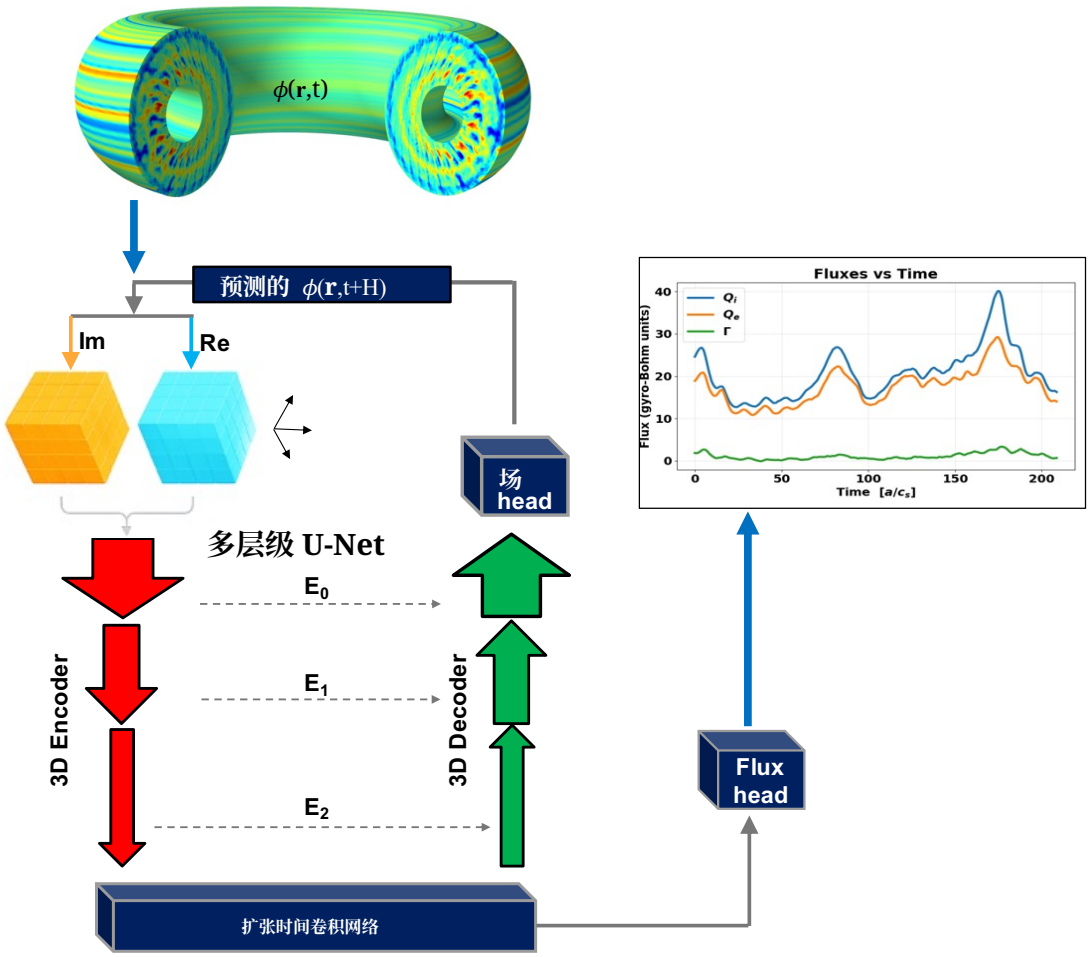

图 1： GKFieldFlow 模型及自回归场势计算循环的示意图。湍流场势 $\phi(\mathbf{r}\ t)$ 和通量（Q_i, Q_e, Γ）由 CGYRO 非线性回旋动力学代码预先计算，用于训练神经网络。该 FieldFlow-Net 架构设计如下：(i) 多层级三维 U-Net 编码器从一段较短历史记录中的复数场（实部/虚部通道）提取空间湍流特征；(ii) 扩张时间卷积网络（TCN）对快照之间的时间依赖关系进行建模，形成最终的潜在$\widehat{}$表征，并将其输入两个分支：场分支驱动三维解码器，以预测 $\Phi(\mathbf{r}\ t+H)$；通量头则预测预测时域内的（Q_i, Q_e, Γ）。为清晰起见，此处省略了具体层维度和超参数。

可根据完全非线性回旋动理学模拟重建未来场并预测输运通量。

图 1 展示了 GKFieldFlow 的示意图。模型以短时间上下文窗口 T_c内的复势场$\phi(\mathbf{r}\ t)$（此处为静电场）为输入，对三维空间结构进行编码，并通过时间卷积网络（TCN）演化潜在表示。输入场在垂直于磁场的平面上采用谱空间表示（k_x, k_y），在 θ上则采用有限差分表示； θ是表示沿磁场变化的极向角。随后，两个输出头分别（i）在完整的（k_x, k_y, θ）网格上重建未来的ϕ 场；（ii）推断相应的离子和电子热通量及粒子通量，且均以物理单位表示。我们还引入内部滚动损失，使模型在训练期间接受多步预测训练，并使用集成滚动预测来量化模型在数百个时间步上的保真度。

由于网络缺乏速度空间信息、依赖物种的动力学矩及控制方程回旋动理学–麦克斯韦方程，并且在时间和空间信息上进行了稀疏化，因此从代理模型的角度来看，场的演化是非马尔可夫的。一项关键成果是确定了最优记忆时间 T_c^*，它能使通量和场的长时域均方根误差最小；我们发现，该时间显著短于底层 CGYRO 模拟中的湍流自相关时间。这使我们的工作处于基于机器学习的代理模型建模、陀螺动理学湍流和极端事件预测的交汇处：我们证明，相对较短的学习型潜在记忆足以维持对输运和湍流的准确长滚动预测，这为构建快速且具备物理感知能力的代理模型提供了新思路，以

非线性回旋动理学动力学。

A. 等离子体湍流与陀螺动理学建模的机器学习代理模型

近期等离子体湍流机器学习代理模型涵盖多种方法，具体取决于所保留的物理过程和目标可观测量。GAIT 等生成模型 [14]表明，潜在自编码器和循环解码器能够再现约化流体模型（如 Hasegawa–Wakatani）中的长序列湍流；而 CNN–LSTM 和 Transformer 架构则已用于根据回旋动理学快照进行短时域场预测 [15]。神经输运回归器（包括 TGLF–SiNN [16] 及相关闭合模型 [17], ）能够快速估算剖面层级的通量，但不会演化场，也无法保持多步动力学一致性。

在等离子体领域之外，编码器–解码器 U-Net 通常被用作流体和偏微分方程代理建模中的单帧场回归器 [12, 13], ，但这类架构不具备时间记忆、自回归稳定性或联合输运预测能力。本研究超越了这些非时序 U-Net 基线方法，提出一种用于非线性陀螺动理学湍流的三维时空代理模型；该模型直接基于非线性CGYRO数据训练潜在记忆模型，从而在多个预测时域上联合预测未来场和输运。

表 I 对相关类别进行了结构化比较，并总结了它们与本研究的关联。以往的代理模型通常：(i) 基于简化的湍流模型，而非第一性原理陀螺动理学；(ii) 生成场，但不预测相关输运；或 (iii) 回归输运，却未保留其底层时空结构。与以往的机器学习代理模型相比，GKFieldFlow 采用三维时空神经架构，联合预测未来场和通量。这使得模型能够对非线性陀螺动理学湍流进行长时域、高保真度的自回归预测；对于本文展示的代表性 DIII-D L模测试案例，在匹配物理时间区间的条件下，相较于 CGYRO，其计算加速比为 $\sim \mathcal{O}(10^2)\times - \mathcal{O}(10^3)\times$，同时降低了 GPU资源使用量。

本文其余部分安排如下。第二节介绍 GKFieldFlow 模型，并概述其底层 FieldFlow-Net架构，包括数据结构、3D 空间编码器—解码器，以及用于潜在状态演化的时间卷积网络（TCN）。第三节介绍如何使用洛伦兹谱宽度缩减径向维度。第四节考察 U-Net骨干网络的多层级结构，并评估深度对性能的影响。第五节展示对时间上下文大小 T_c 的扫描结果，并确定适用于基于 TCN 的预测的最佳窗口。第六节评估长时域滚动稳定性，并表明 GK-FieldFlow 在多个湍流自相关时间内保持了相位相干性、模态结构和通量预测精度。最后，第八节总结研究结果并讨论未来的发展方向。

II. FIELDFLOW-NET 架构：采用时间 TCN 动力学的三维 U-Net 编码器 — 解码器

A. 架构渊源：三维卷积、U-Net 和 TCN

本小节简要介绍核心架构要素的背景——三维卷积编码器、U-Net 风格的空间解码器，以及因果时间卷积网络——并说明它们与等离子体湍流时空代理建模的相关性。

扩展至体数据的卷积神经网络（三维卷积神经网络）[18] 使这类架构能够直接处理三维场，因此尤其适用于等离子体物理学：回旋动力学模型和约化模型会产生固有的三维（或更高维）结构。具体而言，三维卷积可在三个周期性方向上提供平移等变滤波，并能高效捕捉湍流涨落的局部空间相干性。近期研究已将三维卷积神经网络用于回旋动力学诊断指标、斑块跟踪和体数据重建。

基于 U-Net [19]的神经网络架构已成为在高维空间域中学习结构化映射的标准。U-Net 架构最初是为生物医学图像分割开发的，它引入了层次化编码器—解码器结构的概念，并通过跳跃连接将对应的分辨率层级连接起来。这种设计显著改善了梯度流，同时使高分辨率空间信息能够绕过深层瓶颈。此后，U-Net 变体已广泛应用于各种科学领域，包括湍流建模、气候预测、体积图像重建和多物理场模拟。

为了以符合物理规律的方式建模时间动力学，我们采用时间卷积网络（TCN） [20, 21], 这一因果架构。其膨胀一维卷积无需借助循环单元，即可提供较大的感受野。TCN 已成功应用于视频处理、气候时间序列和物理信息序列建模；在根据一段过去状态预测下一状态时，它还能天然地保持因果性。值得注意的是，膨胀卷积使网络能够学习多尺度时间结构；在陀螺动理学湍流中，去相关时间、自相关长度和带状流振荡预计会在相隔甚远的尺度上共存。

表 I：等离子体湍流代表性机器学习代理模型的比较。 GKFieldFlow 针对非线性陀螺动理学湍流，可在多个预测时域上联合预测场与通量。

模型	物理状态	架构
GAIT（Clavier 2025）	降阶 HW 模型	变分自编码器 + 循环式生成式解码器
GyroSwin / CNN–LSTM	回旋动理学/流体快照	二维卷积神经网络 +循环式（长短期记忆网络/Transformer）
TGLF–SiNN	约化回旋动理学输运闭合	神经网络回归（无场演化）
流体 U-Net 代理基线	非等离子体偏微分方程 / 流体湍流（不涉及回旋动理学）	用于场回归的编码器–解码器 U-Net；不具备记忆功能的单步预测；用于流体/偏微分方程代理模型 [12, 13]
GKFieldFlow（本研究）	非线性回旋动理学（CGYRO）	三维卷积神经网络编码器 + 时间卷积网络，联合场+通量预测

B. 自回归 GKFieldFlow 模型概述

本文介绍的模型称为 GKFieldFlow *U-Net–TCN 自回归代理模型*，它将这些进展整合为统一的三维时空架构，专为 CGYRO陀螺动理学代码设计。其目标有两个：

1. 预测静电势 $\Phi(\mathbf{r}\ t)$ 在任意预测时域 H 内的非线性演化，得到 $\Phi(\mathbf{r}\ t+H)$；并且

2. 直接从潜在时间表示中推断相应的离子热通量（Q_i）、电子热通量（Q_e）和粒子通量（Γ）。

GKFieldFlow 的架构旨在体现陀螺动理学湍流的两个关键特性：强烈的多尺度空间结构，以及有限但不长的时间依赖性。下文将 GKField-Flow 中使用的静电场势称为 Φ （以区别于 ϕ），从而将其与 CGYRO 计算区分开来。与以静态快照或瞬时通量为训练对象的既有深度代理模型不同，我们的方法在潜在空间中学习一种时间动力学规律。这首次整合了：(i) 直接作用于（k_x, k_y, θ）体积势场的三维卷积编码器；(ii) 用于重建全分辨率未来场的 U-Net 风格解码器；以及 (iii) 随时间演化潜在表示序列的扩张 TCN。编码器、解码器和 TCN 的层配置详见附录 A。

因此，该架构采用自回归方式：对$\Phi(\mathbf{r}\ t+H)$的推断结果可以递归地反馈至模型中，以生成长时域轨迹展开，从而以更低成本预测湍流动力学。

C. CGYRO 数据与物理输入

1. *Electrostatic Potential Fields*

CGYRO以谱空间形式输出随时间演化的三维静电势，其中径向和双法向采用谱空间表示，极向采用有限差分网格$\phi(\mathbf{r}\ t) \rightarrow \phi(k_x, k_y, \theta; t)$。在每个保存的时间切片 t_k，模型接收：

- $\Re(\phi)$ — real component,
- $\Im(\phi)$ — imaginary component.

这两个分量被视为不同的输入通道，因此输入张量的形状为：

$$\phi_{\text{input}} \in \mathbb{R}^{T\times 2\times R\times \Theta\times N_y}. \tag{1}$$

其中， T表示时间切片的数量，因子 2 对应于复势的实部和虚部， R 表示保留的径向傅里叶（或谱空间）模态数量， Θ表示 θ 方向上的极向网格点数量， N_y 表示双法向（环向）傅里叶模态数量。将两个分量都保留为通道，体现了复模振幅正交分量的物理含义。相位信息在确定非线性耦合、环向模旋转以及湍流涡旋结构方面发挥着核心作用。输入静电势 Φ 以形状为 $[B,\ 2,\ R,\ \Theta,\ N_{k_y}]$的五维张量形式输入网络，其中 B 表示小批量大小。因此，该张量表示完整的三维、局部时间湍流状态 $\phi(r,\ \theta,\ \alpha)$，在 $(r,\ \alpha)$ 中以谱空间形式解析（即分别对应 k_x 和 k_y 波数），并在 θ 中进行离散化。在典型的 CGYRO 模拟中，径向谱分辨率为 $R \sim \mathcal{O}(10^2\text{–}10^3)$，而极向分辨率为$\Theta \gtrsim 24$，具体取决于所建模的物理机制。正如后文所述，我们基于对 T 谱的洛伦兹拟合，对径向傅里叶模态进行物理信息驱动的降维，从而

仅保留径向支撑中与动力学相关的部分。对于本文所使用的 CGYRO 数据集，原始维度为 $(R,\ \Theta,\ N_{k_y}) = (324、24、16)$。

应用降阶模型谱裁剪后，提供给编码器的输入张量形状为

$$[B,\ 2,\ R_0,\ \Theta_0,\ N_{k_y}] \tag{2}$$

其中 $R_0 = a\,\Delta k_x,\quad 1 < a < 5$ 为径向谱中洛伦兹型宽度的比例。该降阶表示保留了关键的湍流特征，同时大幅提高了计算效率。此处引入的维度将在 U-Net–TCN 架构的全文说明中保持一致。

2. *Flux Targets*

CGYRO 还提供物种依赖的湍流通量：

$$y(t_k) = \big(Q_i(t_k),\, Q_e(t_k),\, \Gamma(t_k)\big), \tag{3}$$

其时间分辨率与所存储的 Φ 场相同。训练仅使用统计稳态饱和区间；早期瞬态时段不纳入其中。额外输运通道（如杂质能量）的计算将留待未来研究。

3. *Rationale for 3D Convolutions*

三维卷积保留了湍流的回旋动力学结构，该结构无法在 (r, θ, ζ) 中分离：气球模宇称、涡旋拉伸、带状流剪切和环向相位相关都依赖完整的三维分辨率。卷积神经网络能够学习空间不变量，包括：径向相关长度、极向倾斜与气球模结构、涡旋的环向相干性、局部剪切抑制模式、流带形成与破裂。三维卷积算子：

$$(\mathrm{Conv3D} * \Phi)(k_x, k_y, \theta) \tag{4}$$

能够同时捕捉三个方向上的相关性。

4. *Training Windowing vs. Autoregressive Deployment*

在训练期间使用的时间上下文，与代理模型最终部署时所处的自回归预测物理状态之间，存在一个重要的方法论区别。在训练过程中，时间卷积网络接收由连续场快照组成的有限窗口 $\{\Phi(t-T_c+1)\ldots, \Phi(t)\}$，并经过优化以预测 $\Phi(t+H)$ 及其相关的输运通量。从严格的信息论角度来看，这对应于窗口条件推断任务，而非纯粹的逐步预测器，因为训练损失是在整个输入窗口范围内使用真实数据进行评估的。

然而，至关重要的是，该代理模型仅在自回归滚动模式下进行评估和应用，这满足了基于代理模型的湍流演化所需的运行约束。在这种物理状态下，该模型仅利用截至 t_0 的真实历史数据来预测 $\Phi(t_0+H)$；随后，它会递归地将自身的预测作为输入反馈，以生成 $\Phi(t_0+2H)$、$\Phi(t_0+3H)$，依此类推。在滚动预测的任何阶段，模型都不会访问未来的真实状态；因此，其长时程行为完全取决于学得的时间动力学，以及其内部表示在自生成输入作用下的稳定性。

从一般的机器学习视角来看，基于窗口的训练与自回归部署之间的不匹配可能导致分布偏移，使模型从干净的真实数据输入转向噪声更大的自预测状态输入，进而降低滚动预测的性能。尽管如此，我们的结果（图 6–10）表明，该代理模型保持了出色的定性保真度，保留了谱结构，并在超过五个湍流自相关时间（$\sim$ 1400 步）的滚动预测中再现了输运统计量。这说明模型已学得对物理可容许的湍流状态的稳健表示，使其能够在反复自主演化的过程中保持在稳定吸引子上。

我们假设，对于陀螺动理学湍流这类强物理约束系统，基于窗口的时序训练通过鼓励时间一致性并抑制特定于数据集的捷径，能够提供隐式正则化。因此，长时域滚动稳定性反映了模型是否成功学习到一个受物理约束的流形，从而支持稳定的自回归动力学。

D. 自回归滚动评估

为评估代理模型超越单步通量预测的动力学保真度，我们进行了自回归滚动测试。给定长度为 T_c 的输入窗口（时间上下文），模型以真实 CGYRO 场 $\{\Phi(t_0-(T_c-1))\ t_0$ 为初始状态 $\ldots, \Phi(t_0)\}$，并预测下一个场 $\Phi(t_0+1)$。随后将此预测递归反馈给模型作为输入，替代真实场，使模型将系统向前演化 N_{roll} 步：$\Phi_{\mathrm{in}}(t+1) = \Phi_{\mathrm{pred}}(t+1)$。滚动测试期间不采用教师强制；所有预测均以自由运行模式生成。

E. 训练流程

模型采用 Adam 优化器进行训练 [22], ，并使用学习率调度，在验证误差趋于饱和时减小步长

训练采用早停准则终止，以防止过拟合并确保稳定收敛。损失函数旨在将多时间范围的单时刻通量预测和场重构损失，与其相应的滚动一致性损失结合起来。损失函数计算的详细信息见附录 C。

小批次由从可用时间序列中均匀抽取的时间窗口构成，窗口长度为 T_c 。输入场和目标通量均使用仅基于训练子集计算的统计量进行归一化。所有实验均在现代深度学习框架中实现，并利用混合精度算术提高加速器硬件上的计算效率。

F. 总结与创新

所提出的 GKFieldFlow 模型整合了：

1.**一个三维空间编码器**，用于提取湍流势在 (k,k_y,θ) 上的多尺度几何特征；2.**一个扩张时间卷积网络**，用于学习潜在空间中陀螺动理学湍流的非线性时间演化，从而实现自回归滚动预测；以及 3. **一个双头架构**，其中一个头以完整空间分辨率重建 $\Phi(t+H)$，另一个头则预测相应的非线性通量。

这种体积卷积、U-Net跳跃连接和时间卷积网络序列模型的结合，构建出一种既具有物理可解释性，又能够预测 CGYRO 生成的多尺度非线性演化的代理模型。

III. 通过洛伦兹谱宽估计进行降维

本研究的一项关键目标是构建一种高保真、计算高效的代理模型，仅使用显著精简的输入特征集即可预测陀螺动理学湍流通量。原始 CGYRO输出在 k_x 中针对每个（k_y， θ）包含数百个径向傅里叶模，导致任何机器学习模型都需要处理极其庞大的输入张量。在 CGYRO 非线性模拟中，为准确预测湍流输运通量，需要保留完整维度。然而，陀螺动理学湍流具有一种已知的谱结构：径向波数谱中只有一个紧凑区域承载着动力学相关的涨落能量。这一观察促使我们采用基于物理的降维流程，识别占主导地位的 k_x 区域并予以保留，同时系统地舍弃高-$|k_x|$模态——它们对输运的贡献微乎其微，却会显著增大数据量。

A. 漂移波湍流谱的洛伦兹结构

静电势涨落的径向谱，

$$S(k_x) \equiv \left\langle |\phi(k_x, k_y, \theta_{\text{out}})|^2 \right\rangle_t , \tag{5}$$

在 $k_x = 0$ 附近呈现尖峰，并表现出近似洛伦兹包络或修正洛伦兹包络的尾部。这种谱形式是其潜在实空间湍流结构的直接结果。漂移波湍流的特征是径向两点相关函数呈指数衰减，这种衰减由非线性涡旋混合和剪切流的去相关效应共同驱动。指数相关性意味着傅里叶空间中的洛伦兹功率谱，这是统计理论中的经典结果[23]。

此外，带状流会对湍流涡旋产生剪切作用，导致谱展宽，从而进一步强化类洛伦兹形状 [24]。漂移波湍流的理论处理表明，径向指数去相关与流束动力学相结合时，会自然产生 k_x [1] 中的洛伦兹谱。现代非线性陀螺动理学模拟，包括对离子温度梯度模、俘获电子模、电子温度梯度和微撕裂湍流的研究，都证实在广泛的物理状态下，饱和态径向谱均能很好地用洛伦兹包络拟合[25]。这一稳健的物理基础为使用洛伦兹型宽度定量衡量湍流相关尺度提供了自然框架。

B. 测试案例：非线性 CGYRO 模拟

本研究所采用的代表性非线性回旋动力学模拟结果如图2所示。面板 (a)–(c) 分别展示了湍流热通量时间序列、对应的副法向谱分布以及主导线性本征模结构。该案例为离子尺度模拟，基准波数为 $\Delta k_y\rho_s$ =0.067，包含 $N_{k_y} = 16$ 个副法向模，因此总 k_y 谱范围为 ≈ 1.0。模拟在 DIII-D托卡马克的 L模放电中、归一化小半径 $r/a = 0.8$ 处进行。数值分辨率包括 $N_r = 324$ 个径向傅里叶项和 $N_\theta = 24$ 个极向网格点。模拟中已明确去除瞬态过程，所示时间窗口对应于饱和湍流态。

主要的热通量 Q_D 由离子（氘）通道传输。线性 CGYRO分析表明，最不稳定模出现在图2(b)中 k_y-谱峰值附近，沿离子抗磁方向传播，

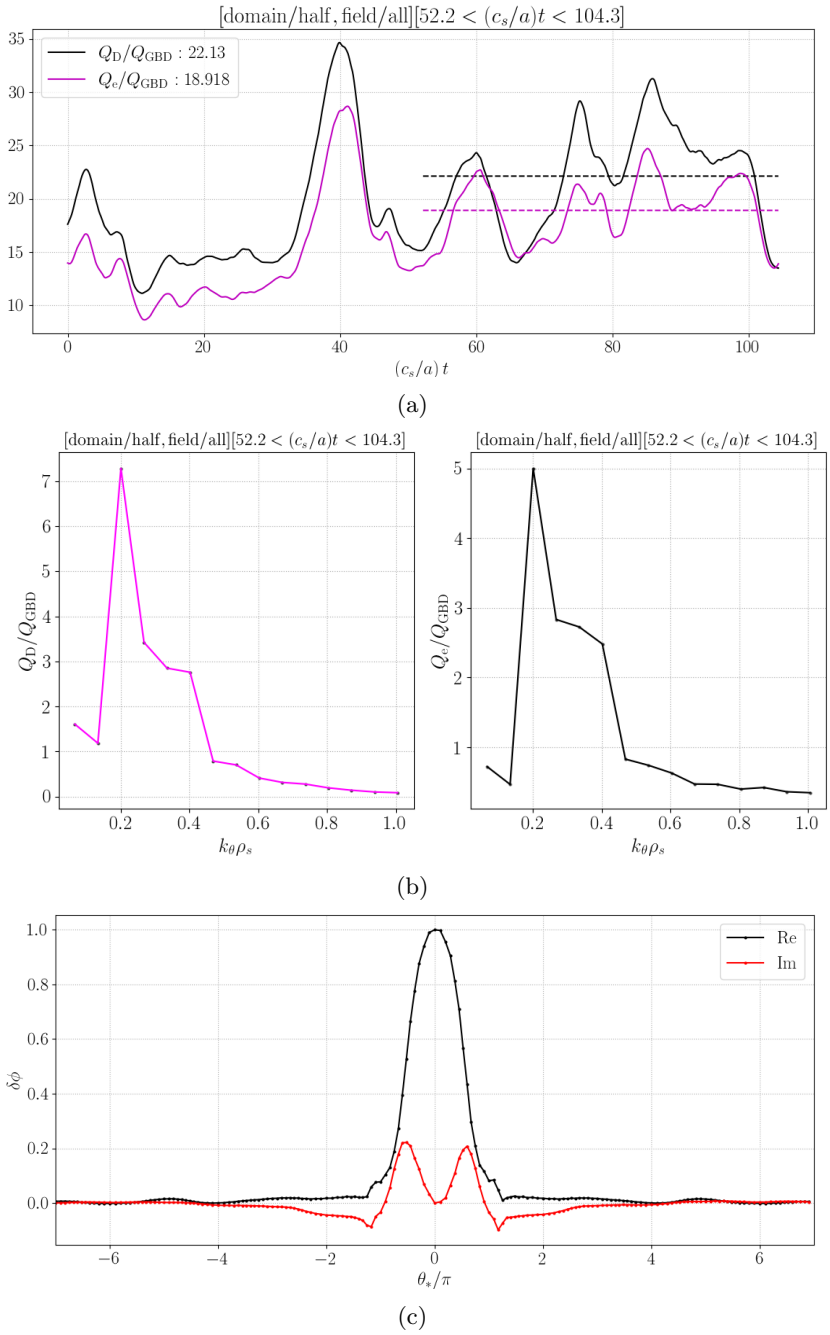

图2：(a) 测试用例的非线性 CGYRO 模拟通量时间序列，分别显示离子（氘）和电子能量 Q_D ，以及 Q_e ，单位为使用非线性 CGYRO 计算的回旋玻姆归一化单位；(b) 通量随 k_y 变化的分布；(c) 分布峰值处的线性本征模（来自线性 CGYRO） $k_y = 0.2$。

并呈现出具有显著外侧中平面峰值的气球模奇偶结构 [图 2(c)]。这些特征与环向离子温度梯度模（ITG）不稳定性一致，表明ITG湍流是该物理状态下的主要驱动机制。由于ITG湍流主要为静电性质，本研究重点预测静电势 Φ ，并将其作为代理模型的输入场。对于涉及（Φ， $A_{\|}$）的电磁模拟的扩展将将在未来的工作中进一步探索。

该模拟将作为本文后续部分中训练和评估 GKFieldFlow 的参考数据集。

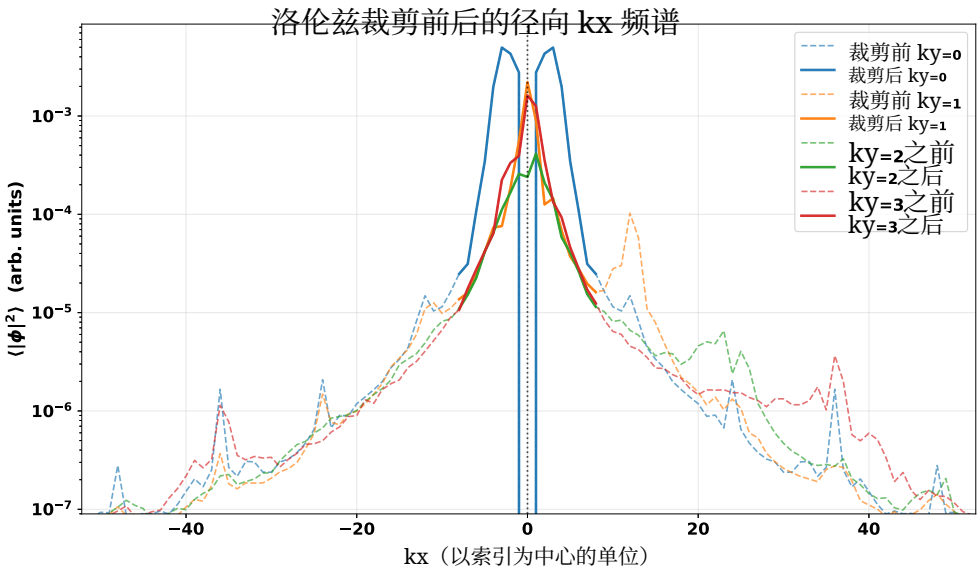

图 3： ± 50 附近径向波数的时间平均径向分布函数的对数图，涵盖前 4 个副法向模（$k_y = 0$ 为区域平均）。实线表示宽度为 $2\Delta k_x$时裁剪后的分布，其中 Δk_x 依据半高全宽（FWHM）准则计算。对于此测试示例，保留的裁剪后径向项数量为$R_c = 17$ ，原始数量为 $R = 324$ 。

C. k_x中的径向谱空间裁剪

为降低输入场的维数，同时保留主要且与动力学相关的内容，我们基于全局径向谱 $S_{\text{global}}(k_x)$的半高全宽（FWHM）准则，进行类洛伦兹宽度估计。如果半高法无法得出明确结果（例如出现平台或肩部结构），则采用基于峰值附近二阶谱矩的次级估计作为备选方案。对于每个数据集，我们计算一个全局径向谱

$$S_{\text{global}}(k_x) = \left\langle |\Phi|^2 \right\rangle_{t,\theta,k_y}, \tag{6}$$

定义为势涨落能量密度的时间与角度平均值。这为径向模分布提供了一种与装置和具体算例无关的度量，常用于表征陀螺动理学模拟中的湍流结构 [4, 26, 27]。我们识别 $S_{\text{global}}(k_x)$的主峰，并采用半高全宽（FWHM）准则估算有效谱宽 Δk_x 。随后，将对称裁剪半径 R_c 设为该谱宽的一个可控倍数，

$$k_x \in [-R_c,\, R_c], \qquad R_c = \alpha\, \Delta k_x, \quad \alpha = \mathcal{O}(1\text{–}4), \tag{7}$$

其中，缩放因子 α 决定了 $S_{\text{global}}(k_x)$中的尾部结构保留多少。

这会生成一个截断场 Φ_{crop} ，在去除高-k_x 成分的同时，保留大部分具有物理意义的湍流能量。这些成分对通量预测的贡献极小，却会增加计算成本。对所有 k_y 均采用相同的裁剪方式，以保持张量的一致性，并避免对个别谱通道造成偏差。这样既保留了主要的径向尺度，又无需针对每种情况单独调整，从而可靠地降低输入维数。

图3展示了这一流程的一个示例，其中给出了前4个副法向模强度径向分布的时间与 θ 平均值的对数图（$k_y = 0$ 为不含$k_x = 0$的带状流）。虚线表示实际分布，其范围延伸至 ± 192；此处我们放大视图，仅显示± 50 项。实线表示宽度为 $2\Delta k_x$ 的裁剪后分布，其中 Δk_x 采用半高全宽（FWHM）方法计算。采用这种裁剪方法后，保留的径向项从 $R_c = 324$ 减少至仅 $R_c = 17$。这种选择保留了物理相关谱段中几乎全部的涨落能量，同时排除了高-$|k_x|$ 尾部；这些尾部最多只占总能量的百分之几的十分之一。尾部主要由振幅较小的结构构成，它们对湍流输运的贡献并不显著，却会大幅增加输入模的数量。

D. 对代理模型效率的影响

减少径向模态的数量可直接降低模型输入张量的维度，从而减少 GKFieldFlow 代理模型的内存占用、训练时间和推理延迟。高维输入可能导致过拟合并降低模型稳定性，尤其是在训练

数据有限的情况下。通过系统地仅移除物理上无关的模态，基于洛伦兹函数的裁剪过程在不牺牲对潜在陀螺动理学动力学保真度的前提下，提高了模型的泛化能力和效率。所得数据集更加紧凑，物理可解释性也更强，因此尤其适合对湍流输运进行快速、预测性的代理建模。

IV. U-Net 深度和径向谱裁剪对预测精度的影响

为量化架构深度和输入谱空间分辨率对空间编码器性能的影响，我们对 (i) U-Net 下采样层级的最大数量和 (ii) 保留的径向谱模态数量进行了二维扫描 R_c。本研究中的所有模型均采用一致的通道缩放策略，使特征维度随着空间分辨率层级加深而增加。对于每种架构深度和空间上下文参数组合，我们都训练了一个完整的 GKFieldFlow 模型直至收敛，并使用三个湍流输运通道的归一化均方根误差（NRMSE）均值进行评估（Q_i, Q_e, Γ）。滚动预测从一组均匀分布的起始时刻初始化，并向前推进 560 个时间步；在 t 中采用步长 2，相当于所测试的 CGYRO 模拟中的大约一个湍流自相关时间 $T_{\mathrm{ac}} \approx 9\,a/c_s$（$a$ 为托卡马克等离子体的小半径，$c_s = \sqrt{T_e/m_D}$ 为离子声速，T_e 为电子温度，m_D 为氘质量）。此外，我们采用步长 4 来降低极向分辨率。因此，即使在径向裁剪之前，时间方向和极向上采用步长进行降采样，已使输入数据量减少了 8 倍。

A. 单时刻推理性能

代理模型保真度的首要衡量指标之一，是在给定包含 T_c 个连续陀螺动理学场的输入窗口时，能否推断某个目标时刻的热通量、粒子通量以及湍流静电势。在湍流机器学习应用中，对于高维多尺度动力系统，归一化单位下均方根误差约为 10^{-1}，或物理单位下相对误差为百分之几，通常被认为是良好的表现 [28, 29]。按照这一标准，我们的模型表现出极高的准确度：归一化通量均方根误差介于 1.1×10^{-2}–2.0×10^{-2}，相应的物理误差约为 5×10^{-2}–1.2×10^{-1}。静电势的归一化误差为 3%–4%。

a. 不同 *U–Net* 深度和径向分辨率下的单时刻推断性能 表 II 报告了在扫描 U-Net 深度和径向谱截断组合时，单时刻通量推断的最佳轮次误差 R_c。$R_c = 11, 17, 33$ 和 49 的数值分别对应 $1.25\times$、$2\times$、$3\times$ 和 $4\times$ 洛伦兹型宽度 Δk_x。从标准机器学习基准的角度来看，所得 NRMSE 值非常低：许多配置下的通量误差介于 1.8%–3.0%，远在混沌动力系统非线性回归通常被视为“良好”至“非常好”的表现范围之内。势场误差通常低于 2.5%，进一步表明，精简后的空间表示保留了准确推断通量所需的主要物理信息。

可以看出几个明显趋势。首先，对于大幅裁剪的输入（$R_c = 11$ 和 17），将 U–Net 的深度从一级增加到两级，可显著降低所有物种的通量均方根误差。这表明，当输入仅包含最大尺度的径向特征时，更深的层次编码更有利。由于 $R_c = 11$ 的 Θ维度会塌缩，因此没有采用第三级；但对于 $R_c = 17$，第三级仅带来边际性的额外改进。

对于中等分辨率（$R_c = 33$），从一级增加到两级时，性能仅在最后两列有所提升；增加到三级后，性能继续略有改善，但收益有限。这种物理状态似乎处于一个过渡区间：此时编码器的下采样代价日益增大，但尚未造成不利影响。

相比之下，对于高分辨率（$R_c = 49$），三级模型的表现明显更差，通量误差几乎是两级网络的两倍。在这种情况下，空间下采样造成了过度压缩：更深的瓶颈层无法保留精细的径向结构和较短的相关长度，导致推理准确率下降。

需要注意的是，RMSE 在 10^{-3} 层面的差异处于神经网络训练预期的随机波动范围内。因此，只有较大的性能差异——例如低 R_c 时从一层到两层带来的显著提升，或三层模型在 $R_c = 49$ 时的急剧退化——才应被视为具有统计意义。

总体而言，这些结果进一步印证了本文的一个核心结论：仅保留极少径向模态（$R_c = 11$–17）的降阶表示，表现出乎意料地好。这验证了本文采用的基于物理的降阶建模策略。为在高谱分辨率下实现更深层编码器而进行的改进，是未来研究的一个重要方向。

B. 自回归滚动性能

单时刻推理指标为衡量网络逼近非线性

表 II：针对 U-Net 深度（层级）和保留的径向傅里叶模数量 R_c 的扫描，在最佳训练轮次下的单时间步推理误差。粗体条目表示深度增加 $\geq 20\%$ 后各项指标的改进。

层级	R_c	训练损失	验证损失	均方根误差$_{Q_i}$	均方根误差$_{Q_e}$	均方根误差$_{\Gamma}$	均方根误差$_{\Phi}$
1	11	0.00923	0.00169	0.03096	0.02898	0.03075	0.02493
2	11	**0.00473**	**0.00084**	**0.01882**	**0.01669**	0.02646	**0.01770**
1	11	0.00923	0.00169	0.03096	0.02898	0.03075	0.02493
2	11	**0.00473**	**0.00084**	**0.01882**	**0.01669**	0.02646	**0.01770**
1	17	0.01449	0.00163	0.02503	0.02024	0.02862	0.02839
2	17	**0.00789**	**0.00111**	**0.01940**	0.02322	**0.02442**	**0.02193**
3	17	**0.00589**	0.00118	0.02337	0.02903	0.02733	0.01927
1	33	0.01440	0.00181	0.02196	0.02552	0.03374	0.02904
2	33	**0.00880**	**0.00133**	0.02183	**0.02564**	**0.02238**	0.02513
3	33	0.00730	0.00112	0.02290	0.02557	**0.02241**	**0.02109**
1	49	0.01370	0.00130	0.02107	0.02064	0.02741	0.02464
2	49	0.01110	0.00142	0.02086	0.02662	0.02388	0.02607
3	49	0.01587	0.00342	0.03785	0.04736	0.04493	0.03494

映射 $\Phi(t) \mapsto (Q_i,\ Q_e,\ \Gamma)(t+\Delta t)$提供了基准。这类单步损失在文献中被广泛用作衡量纯函数逼近能力的指标。然而，对于描述湍流动力学的自回归代理模型而言，单步精度不足以预测滚动预测性能。即使单步通量均方根误差很小，Φ 中的微小相位或振幅误差也可能在混沌时间演化过程中不断放大。因此，单步精度看似相近的模型，在滚动预测过程中可能表现出显著差异。我们的结果清楚地证明了这一点：诸如 (2，17) 和 (3，17) 这样的架构，单时刻通量均方根误差相近，但由于 (3，17) 对 ϕ多尺度结构的重建效果更好，其长时域表现显著提升。

因此，评估代理模型保真度既需要进行单时刻测试，也需要考察滚动预测诊断；后者对学习到的潜在动力学稳定性更为敏感。

为评估长期动力学保真度，我们进行自回归滚动预测：模型预测 $\Phi(t+H)$ 及其相关通量，然后将自身的推断结果反馈为输入。此过程在无法访问真实 CGYRO 数据的情况下持续 N_{roll} 步。

图 4 展示了以下滚动预测的归一化均方根误差（NRMSE）：(a) 湍流通量、(b) 湍流势 Φ，$(k_y > 0)$ 和 (c) 纬向流势Φ，$(k_y = 0)$，误差随保留的径向谱模态数量 R_c 及 U-Net 最大深度的变化情况。扫描维度与表 II 相同，即层级：(1,2,3) 对比 R_c：(11，17，33，49)。该误差分布呈现出空间 U-Net 编码器深度与保留的径向谱模态数量 R_c之间的非平凡关系。在强裁剪区域（$R_c = 11$ 和 17）中，湍流势仅包含大尺度径向结构。此时，增加编码器层级数量会使预测精度单调提升：更深的 U-Net 可扩大空间感受野，并为 $\phi(\mathbf{r}\ t)$ 提供更具表达能力的层次表示。对于 $R_c = 11$，仅执行两个下采样阶段，因为第三次步长为 2 的缩减会使 Θ 维度坍缩；尽管如此，从一个层级增加到两个层级仍会显著降低 NRMSE。

当谱带宽更大（$R_c = 33$ 和 49）时，模型表现会发生质的变化。在这一高分辨率区域，三级 U-Net 的表现比两级模型更差 。保留更多径向模态会引入更精细的空间尺度和更短的径向相关长度；连续进行多层步长为 2 的下采样会过度压缩这些特征，使对准确通量预测至关重要的信息变得模糊或丢失。当R_c 较大时，三级网络表现较差，这表明编码器架构必须随着输入分辨率的提高而调整。

这些观察结果确立了一项分辨率依赖的设计原则：粗略裁剪的输入受益于更深的层次编码器，而高分辨率场则需要较浅的 *U-Net*，除非引入架构修改以防止过度压缩。需要强调的是，本研究的目标并非捕捉回旋动力学势的完整空间分辨率，而是开发一种<小>精简</小>代理模型，使其能够以尽可能少的信息实现最佳性能。客观比较图4所示的所有测试设置后，表现最佳的配置依次为：首先是具有 3 个 U-Net 层级的 $R_c = 17$ 径向项，其次是具有 2 个 U-Net 层级的 $R_c = 11$径向项。在此背景下，图4的结果意义重大：仅保留 $R_c = 11$ 径向傅里叶模态的模型，其表现与使用 $R_c = 17$甚至 $R_c = 33$的模型相当，有时甚至更好，

无论采用两个还是三个 U-Net 层级，结果都是如此。这表明，准确预测通量所必需的大部分信息都包含在最低阶径向谱中，因此验证了本文采用的降分辨率建模策略。

有趣的是，单时刻推理指标（训练损失、验证损失，以及 Q_i、 Q_e 和 Γ 的单步均方根误差）与长时域滚动误差并无直接相关性。在单步通量推断中表现出色的模型，例如 (2，17) 和 (3，17)，其滚动预测表现却大相径庭。

如图 4(a)–(c) 所示，决定滚动预测精度的并非单时刻通量误差，而是模型能否在 $k_y = 0$ （区域平均流）和 $k_y > 0$（漂移波）两个通道中重建湍流电势 ϕ 。尽管 (3，17) 模型的单步通量均方根误差略高于 (2，17)，但其在 $\Phi(k_y = 0)$ 和 $\Phi(k_y > 0)$ 上的归一化均方根误差始终更低，表明其具有更强的相位相干性、更小的误差放大效应，以及所学时间动态更稳定。

这凸显了自回归湍流建模的一项关键原则：滚动预测性能主要取决于潜在动力学表征的稳定性和准确性，而非单时刻通量推断的准确性。

虽然更深的 U-Net 和其他编码器设计或许能更有效地利用高分辨率输入（$R_c \gtrsim 33$），但这些改进超出了本研究的范围。相反，我们着重于验证一种紧凑且受物理启发的降阶表征的有效性。针对更高谱带宽量身定制的增强架构，将是未来的研究方向。综合来看，这些结果表明，最优编码器深度必须与输入场的物理内容相匹配；只有通过适当的架构修改，深层网络才能在高谱分辨率下发挥效用。

V. 时间卷积网络的最优时间上下文 T_c

设计自回归陀螺动理学代理模型时，一个核心问题是：模型究竟需要多长的时间历史，才能准确推进湍流状态？为确定神经代理模型准确重建湍流动力学及相关热通量和粒子通量所需的有效时间记忆，我们对时间输入窗口 T_c进行了系统扫描。对于每个 T_c，我们都使用相同的 U-Net–TCN 架构训练一个独立模型；针对每个 T_c，从 5 次不同运行中选取表现最佳的轮次；并在 60 个滚动初始时刻上评估集成平均滚动误差，滚动长度固定为 280 步。对于此处采用的步长为 4 的时间采样，这相当于一个湍流自相关时间（对于此测试案例为 $280 \times 4 \times dt \approx 9a/c_s$，在 CGYRO 测试案例中为 $dt = 0.008$ ）。

基于这一框架，我们考察了预测精度对时间上下文长度T_c的依赖关系。结果如图5所示，其中总结了在时间卷积网络模型 GKFieldFlow 中改变时间上下文窗口 T_c 的影响；该模型的滚动预测跨度约为一个湍流自相关时间 T_{ac}。我们展示了三项诊断指标：(i) 预测湍流通量的归一化均方根误差（Q_i， Q_e， Γ）；(ii) 区域平均流（$k_y = 0$）和湍流（$k_y > 0$）分量的势振幅归一化均方根误差；(iii) 圆形相干性指标，用于衡量预测傅里叶模态与真实傅里叶模态之间的相位对齐程度。圆形相干性数值 $C_\phi \approx 1$ 表明模型准确再现了湍流相位结构（推导 C_ϕ的详细信息见附录B）。这些指标共同表征了自回归代理模型的预测精度和结构一致性。

图 5 中的 $T_c = 1$ 情形对应纯即时空间代理模型，其预测仅以单个场快照为条件，不包含任何时间上下文。该设置无法访问过去或未来的状态，因此可作为衡量时间窗口化所带来额外价值的清晰基线。虽然此情形未提供时间历史，但单个湍流快照的空间结构和振幅蕴含了关于输运的重要线索。由于动力学受限于一组狭窄的物理可容许状态，代理模型实际上学会了将每个快照校正或稳定到这组状态附近，而非显式地对时间演化进行建模。因此，尽管缺少时间记忆， $T_c = 1$ 情形仍取得了有竞争力的性能。

所有诊断指标均呈现出一致的趋势。随着 T_c 增大，归一化误差在不确定性范围内减小，这表明时间卷积网络能够受益于更多上下文，并从潜在状态的时间历史中提取更多预测性结构。这一趋势会持续，直到窗口长度达到约

$$T_c^\star \simeq 20 \ \ (\text{in model time steps}), \tag{8}$$

超过这一点后，误差又开始上升。在这一最小值处，相较于 $T_c = 1$ 配置，通量归一化均方根误差降低了近 $\sim 50\%$，且区域平均流和非零 k_y 分量的电势均达到最佳重建保真度。重要的是，图5c显示，在该物理状态下，低值和中等 k_y 下的圆相干性仍接近 1，并且高于其他所有 T_c 值下的相干性。这表明模型在滚动预测过程中保持了相位对齐，并避免了快速去相关。

当 $T_c^\star$ 处出现极小值，反映了两种相互竞争效应之间的平衡。更大的窗口提供更多时间信息，并有效地

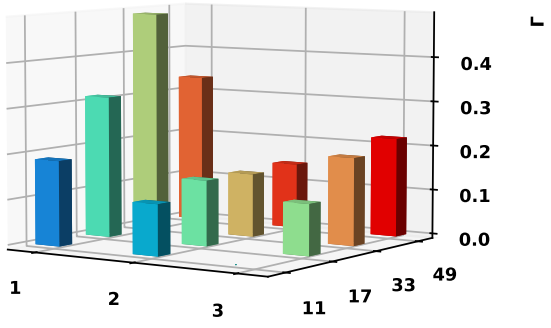

(a) 湍流通量

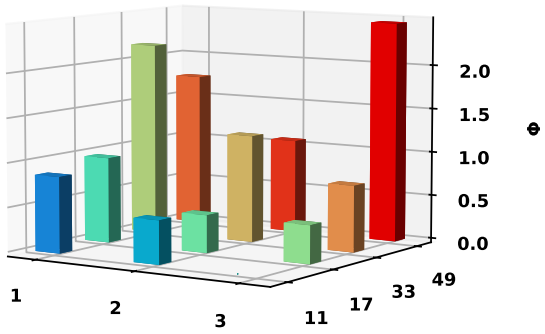

(b) 湍流势 Φ，$(k_y > 0)$

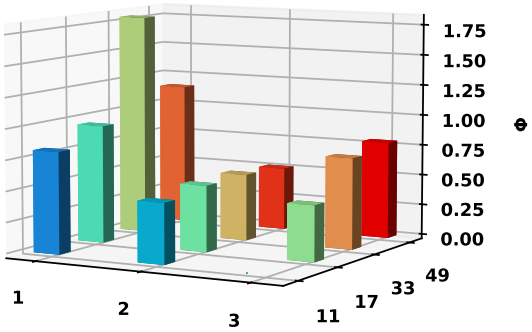

(c) 带状流势 Φ，$(k_y = 0)$

图4：湍流通量 (a)、湍流势 Φ，$(k_y > 0)$ 和带状流势 Φ，$(k_y = 0)$ 滚动预测的归一化均方根误差（NRMSE），随保留的径向谱模态数量 R_c 和 U-Net 最大深度变化。对于 $R_c = 11$，由于 Θ 维度塌缩，只能进行两级下采样。

延长模型可用的记忆长度，从而改善对短于湍流去相关时间尺度的预测。然而，随着 T_c 进一步增大，新增的历史信息主要由已去相关的湍流涨落构成，其相位已无法预测输运，这会增加有效学习复杂度，并降低泛化性能。当 T_c 足够大时，这种额外的变异性在训练过程中会起到噪声的作用，并增加优化难度，表现为 $T_c \gtrsim 20$ 的性能下降。因此，这种非单调趋势可解释为扩展上下文带来的信息增益与噪声或弱相关输入造成的误差累积之间的竞争。

总体而言，这些结果表明，时间卷积网络能够有效利用陀螺动理学场中的短程时间依赖关系，而过长的时间上下文则会引入冗余信息，使预测信号不堪重负。因此，误差随 T_c 变化呈现的 U 形关系，与有限的信息记忆以及从基于快照的数据中学习混沌湍流动力学时固有的偏差—方差权衡相一致。

VI. 最优时间上下文下的长时域滚动稳定性

A. 滚动测试的动机

虽然短时域推理准确率是评估任何代理模型的必要基准，但不足以证明模型是否学到了具有物理意义的动力学表征。在混沌系统中

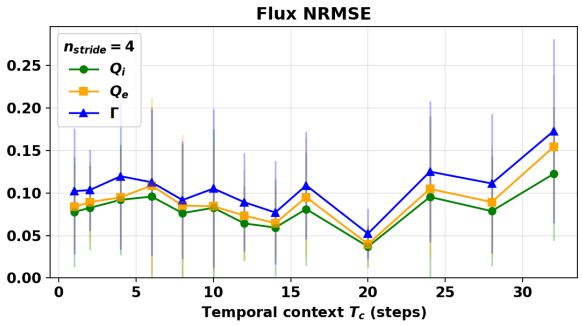

(a)

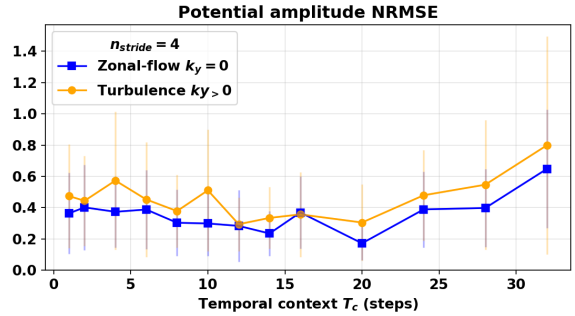

(b)

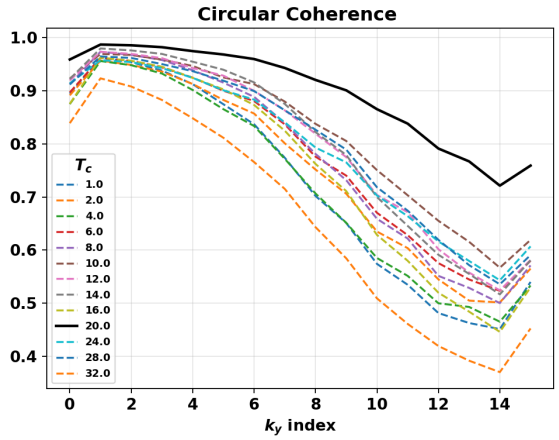

(c)

图5：（a） Q_i、 Q_e和 Γ的通量归一化均方根误差，以及（b）区域平均流和湍流分量的电势振幅归一化均方根误差随时间上下文 T_c的变化。误差条表示 ± 1 次滚动初始化$N = 40 - 60$ 的标准差。（c）所测试时间上下文下，圆相干性随 k_y 谱的变化，显示 $T_c^* = 20$ 具有最高相干性。如（a）和（b）所示，T_c^* 使通量和湍流振幅的归一化均方根误差达到最低。

例如陀螺动理学湍流，短时间窗口内的误差可能仍然很小，但在自由演化过程中仍会迅速发散。因此，评估稳定性、连贯性和预测保真度

在长时域滚动预测中，代理模型自主演化，无法获取真实的未来状态。

本节评估使用时间上下文（$T_c^* = 20$）训练的 GKFieldFlow 代理模型的长时间滚动行为。第五节已将其确定为步长为4的时间稀疏化所对应的最优上下文长度。值得注意的是，该上下文长度远短于湍流自相关时间（$T_c^* \ll T_{\mathrm{ac}}$），因此引出了一个问题：学习到的表示能否支持模型在具有物理意义的时间尺度上稳定演化？为此，我们进行了最长达五个自相关时间的集成滚动测试，并考察相干性、场统计量和输运量。

B. 滚动协议

训练后的模型从多个相互独立的起始时刻 (t_0) 初始化，这些时刻均匀采样自模拟的统计稳态区间。针对每种滚动长度，生成由 40–60 条轨迹组成的集合，以便稳健地评估稳定性和变异性。滚动预测最多进行 1400 个预测步，对应约 ($5T_{\mathrm{ac}}$)。

C. 计算性能与加速比

为量化代理模型带来的计算收益，我们在匹配的物理单位 (a/c_s) 下，将推理成本与底层 CGYRO 模拟进行比较，并考察一系列时间上下文长度 $T_c = 1$、4、8、20，其中 $T_c = 20$是预测误差最低的最优窗口。

对于此处考察的 DIII–D 测试案例，在 6 个节点上运行非线性 CGYRO 模型 $53\,a/c_s$ 需要约 600 秒墙钟时间，每个节点配备 4 个 GPU（Perlmutter 上的 24 个 NVIDIA A100 GPU，位于美国国家能源研究科学计算中心），总成本为 $\sim 1.4 \times 10^4$GPU 秒。相比之下，GKFieldFlow 在单个 GPU 上即可针对相同的物理时间区间进行自回归滚动，其推理成本由 T_c决定。对于精度最高的配置 ($T_c = 20$)，对 $53\,a/c_s$ 进行推理需要 ~ 58 GPU 秒；相较于 CGYRO，按计算量归一化后的加速比约为 2.5×10^2。

以湍流自相关时间 τ_{auto} $=9\,a/c_s$ 作为自然的物理单位，CGYRO 的成本相当于每个自相关时间消耗 $\sim 2.4 \times 10^3$ GPU 秒。对于在 $\Theta = 6$下仍能保持出色精度的紧凑时间上下文，GKFieldFlow 对 $T_c = 4$ 和 $T_c = 8$分别仅需 ~ 2.4 和 ~ 4.2 GPU 秒/自相关时间。将这些成本按相同的 $53\,a/c_s$ 时间区间缩放后，代理模型的总成本为

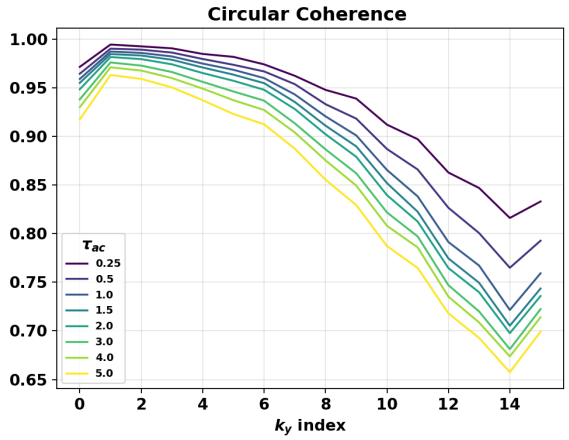

图 6：随着展开时长增加，圆相干性与 k_y 的关系，展开时长以 T_{ac} 为单位。

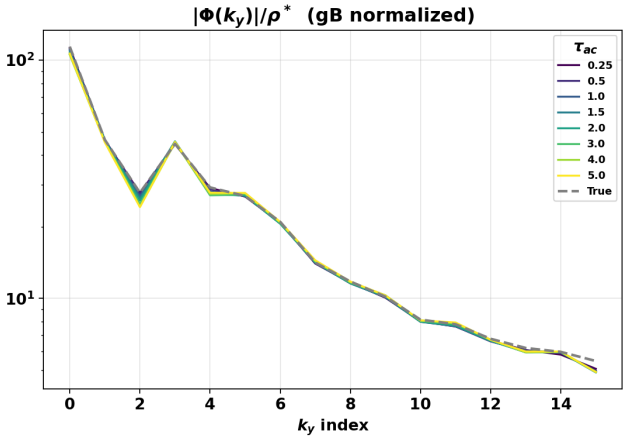

图 7：随着展开时长增加，归一化振幅分布随 k_y 的变化，展开时长以 T_{ac}为单位。

~ 14 和 ~ 25 GPU 秒，相对于 CGYRO 的加速比分别为 $\sim 1.0 \times 10^3$ 和 $\sim 5.7 \times 10^2$。

作为参考，纯瞬时基线（T_c =1）不包含任何显式时间信息，每个自相关时间仅需 $\sim$ 0.9 GPU 秒。在 $53\,a/c_s$ 内，总成本为 ~ 5 GPU 秒，计算量归一化后的最大加速比为 $\sim 2.6 \times 10^3$。这种配置提供了代理推理成本的下限，并展示了可实现的计算加速的全部幅度。

综合来看，这些结果表明，GK-FieldFlow 提供了可调控的精度—成本包络：更高的 T_c 可提升精度，但成本也随之增加；而紧凑的时间上下文（$T_c = 4$–8）则能在保真度与效率之间实现出色的平衡。根据所选的运行点，代理模型可将 GPU 资源总使用量降低 $\mathcal{O}(10^2)$ 至 $\mathcal{O}(10^3)$ 倍，相较于直接进行陀螺动理学非线性模拟，凸显了其在快速探索、参数扫描和实时应用中的价值。

D. 环向模之间的相位相干性

图 6 展示了预测的静电势的圆形相位相干性随环向波数 k_y 和展开时长的变化。

由此可得出几项重要观察。首先，低-k_y 模态（包括带状流分量）在整个滚动窗口内始终保持高度相干。其次，中间- k_y 模态即使超过一个自相关时间，仍保有较强的相干性，其衰减过程平缓且单调，而非突然去相关。第三，高-k_y 模态去相关较快，但即使在 $5T_{\mathrm{ac}}$时仍保持不可忽略的相干性。这种层级特征与陀螺动理学物理相符：大尺度含能模主导输运，其记忆时间比小尺度涨落更长。

图 7 展示了所有滚动时长下，回旋玻姆归一化振幅分布随环向波数的变化情况。总体而言，振幅分布与真实值非常接近。在 $5T_{\mathrm{ac}}$ ，真实振幅的最大相对偏差出现在 $k_y(2) \approx 13\%$。图 6 和图 7 一同表明，GKFieldFlow能够在长时域自回归预测中，对单个 k_y 模态的湍流场相位和振幅进行高精度预测。

E. 滚动预测下的势振幅稳定性

图 8b 展示了势振幅的归一化均方根误差（NRMSE）随展开时长的变化，并分别呈现区域平均带状流（$k_y = 0$）和湍流（$k_y > 0$）的贡献。

湍流分量的初始误差较低，且随滚动长度增加仅缓慢上升；即使在 $5T_{\mathrm{ac}}$时也会在较低水平趋于饱和。区域平均带状流分量则呈现略明显的上升趋势，反映出其内在记忆更长，且对累积相位误差更敏感。关键的是，这两个分量都没有出现失控增长或误差指数放大，表明在自主演化过程中，所学习的动力学仍保持良好的条件性。

F. 长预测时域下的通量预测准确度

图 8a 展示了离子热通量（Q_i）、电子热通量（Q_e）和粒子通量（Γ）的归一化均方根误差随展开时长的变化。

三个输运通道的误差均随滚动长度增加而平滑、逐渐增长，即使达到五个自相关时间，误差仍保持良好的有界性。未观察到明显的突变或不稳定现象。这一行为表明，准确的输运预测

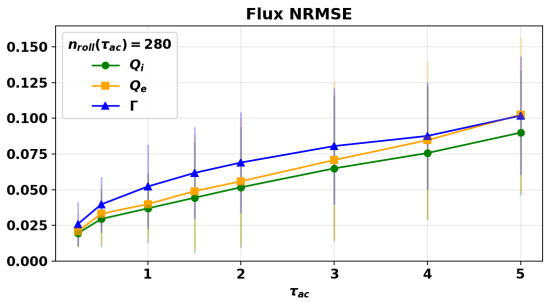

(a)

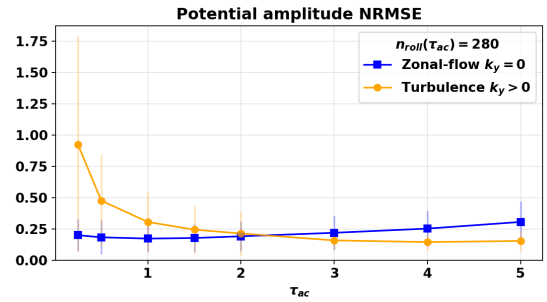

(b)

图 8: （a）Q_i、 Q_e和 Γ的通量归一化均方根误差随展开时长的变化。（b）区域平均流和湍流分量的电势振幅归一化均方根误差随展开时长的变化。

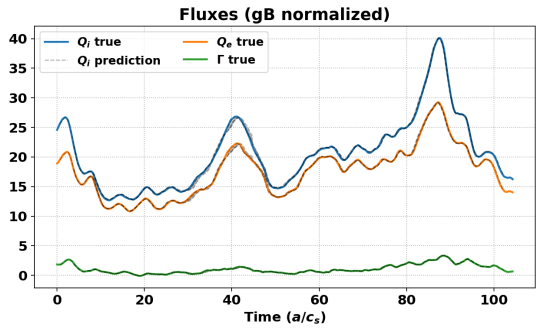

（a） $t_{\text{roll}} = T_{\text{ac}}$

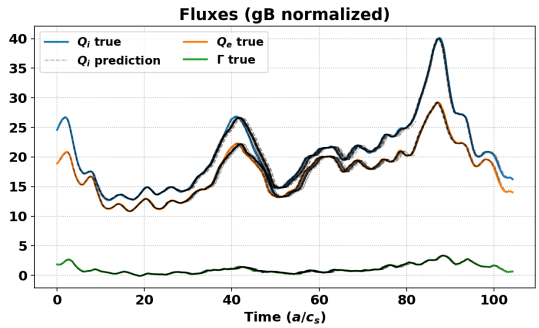

（b） $t_{\text{roll}} = 5T_{\text{ac}}$

图 9: 比较 $1T_{\text{ac}}$ （上）和 $5T_{\text{ac}}$ （下）的真实量与预测量的代表性通量滚动预测时间序列。 T_{ac} 是湍流自相关时间 $\sim 9a/c_s$。

并不要求在训练期间解析完整的湍流自相关时间，而且该代理模型能够捕捉主要的输运相关动力学。

G. 时间分辨的滚动预测轨迹

图 9 和图 10 展示了预测量与真实量的代表性时间轨迹，对比了一个和五个自相关时间的滚动预测结果。图中展示了热通量和粒子通量、湍流涨落强度（$k_y > 0$）以及环向流强度（$k_y = 0$）。

在一个自相关时间后，预测结果与真实值几乎无法区分。值得注意的是，即使经过五个自相关时间，代理模型仍能以很高的保真度再现峰值出现的时间、幅度和长时间包络。集合轨迹仍紧密聚集，表明其行为稳健且稳定。请注意，该模型准确再现了：（i）通量峰值事件的幅度和出现时间；（ii）湍流强度间歇性爆发的特征；（iii）环向流通道中的大幅振荡。这表明，代理模型学会了场动力学与输运之间符合物理规律的相关性，而非仅仅拟合平均值。

H. 物理解释与意义

综合来看，这些结果表明，GKFieldFlow 代理模型学到的是针对任务的湍流状态紧凑表征，而非记忆显式的长时间相关性。尽管最佳训练上下文 $T_c = 20$ 远短于湍流自相关时间，但推断出的潜在状态支持跨越多个 T_{ac}的稳定自主演化。观测到的尺度依赖相干性和输运精度进一步表明，该模型学会了不同模态之间正确的时间刚性层级，这与陀螺动理学物理相符。

I. 结论

本文展示的长时域滚动测试表明，在最优上下文长度 $T_c = 20$ 下训练的 GKFieldFlow 代理模型，在自由演化过程中既稳定又忠实于物理规律。对于最长达五个湍流自相关时间的滚动预测，其相位相干性准确、场误差有界，且输运预测稳健。这些结果证实了这样一种解释：有效学习记忆具有有限长度，

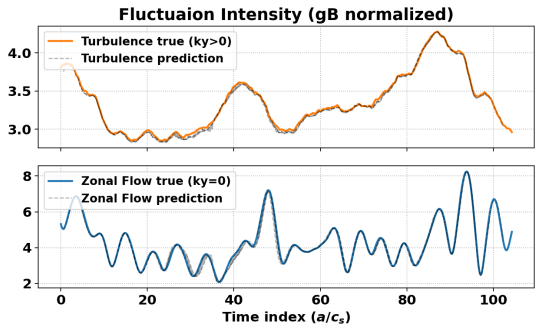

(a) $t_{\text{roll}} = T_{\text{ac}}$

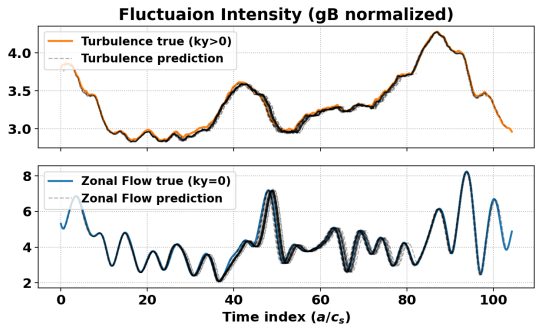

(b) $t_{\text{roll}} = 5T_{\text{ac}}$

图10：对 $1T_{\text{ac}}$ （上）和 $5T_{\text{ac}}$ （下）的真实量与预测量进行比较的代表性湍流和带状流振幅滚动时间序列。

其长度显著短于物理自相关时间，但仍能支持长时域预测能力。这一特性对于未来将基于场的代理模型应用于陀螺动理学湍流的降阶建模、控制和快速输运预测至关重要。

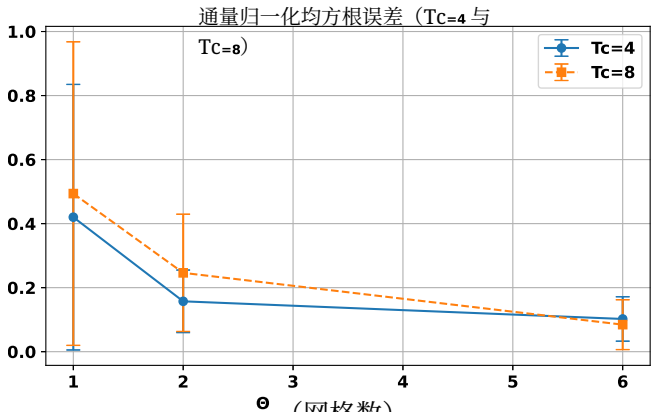

(a)

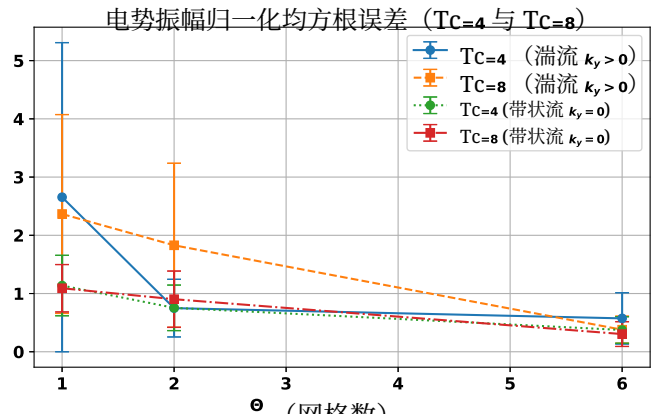

(b)

图 11： (a) 通量的归一化均方根误差；(b) 湍流和带状流的归一化均方根误差，随训练GKFieldFlow所用极向网格点数量（Θ）的变化。均方根误差基于包含 280 步的滚动预测计算，相当于一个湍流自相关时间（$\sim 9a/c_s$）。对于两种时间上下文 $T_c = 4$，，减少 Θ会导致误差增大。

VII. 对极向分辨率（Θ）和信息充分性的敏感性

为评估极向结构在约束代理模型准确性和长时域稳定性方面的作用，我们开展了一项针对性消融研究，系统地减少保留的极向网格点数量 Θ 。这项实验旨在进行压力测试：通过逐步移除极向信息，我们有意降低输入所包含的物理信息，并考察单时刻推断精度和自回归滚动预测行为如何响应。

图 11 总结了在具有代表性的时间窗口长度（T_c =4 和 T_c = 8）下， Θ ={1, 2, 6} 得到的误差。归一化均方根误差基于 280 步的滚动预测计算，相当于一个湍流自相关时间（$\sim 9a/c_s$）。 Θ = 2保留托卡马克等离子体在横截面上的外侧和内侧中平面网格，而 Θ = 1 仅保留外侧中平面网格。结果呈现出明显且单调的趋势。使用Θ = 6 训练的模型，其通量均方根误差始终较低，湍流和带状流振幅的误差也大幅降低。将极向分辨率降至 Θ = 2会导致所有指标显著退化，而极端情况下仅使用外侧中平面（Θ = 1）则会产生较大误差，并显著增加方差。这种表现与关键极向结构的缺失相一致，其中包括气球模局域化和相位关系；已知这些因素对于确定陀螺动理学湍流中的输运和带状流动力学至关重要。

从随时间变化的自回归滚动图中，可以更清楚地看出极向信息减少所带来的影响。图 12 展示了 Θ = 1、Θ = 2 和 Θ = 6 的通量演化代表性“意大利面”图。对于 Θ = 6，代理模型能够保持紧密的轨迹聚束，

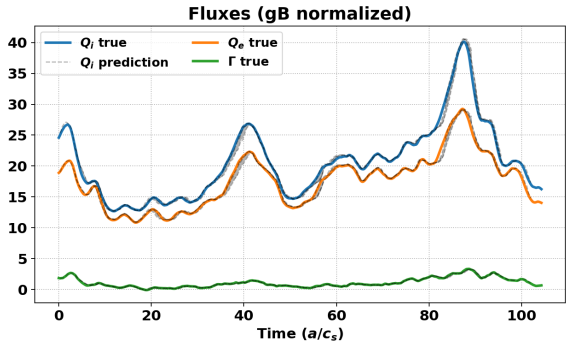

(a)

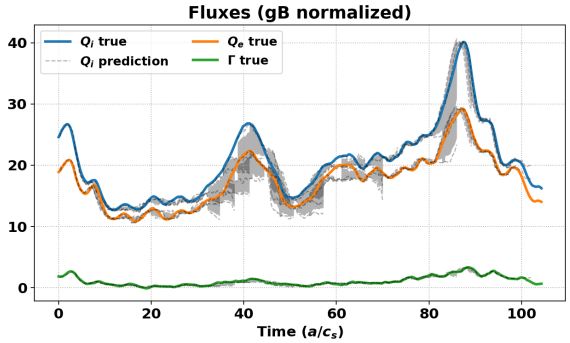

(b)

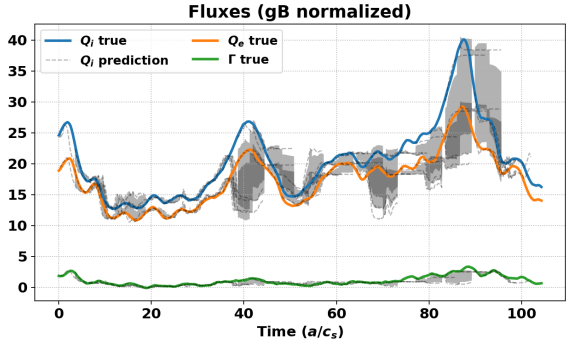

(c)

图 12：$T_c = 8$ 的轨迹集合意大利面图，初始时刻均匀分布；对于$\Theta = 6$，2，1，分别见 (a)、(b) 和 (c)。均方根误差根据步数为 280 的滚动预测计算，相当于一个湍流自相关时间（$\sim 9a/c_s$）。

并在多个湍流自相关时间内呈现准确的平均行为和稳定的长时域演化。在 $\Theta = 2$ 情况下，滚动预测表现出明显增大的离散程度和间歇性偏差，表明其保持在物理可容许流形上的能力有所降低。相比之下，$\Theta = 1$ 情况显示出显著的轨迹发散和保真度的快速丧失，说明单个极向切片不足以在长时域内约束非线性动力学。

综合来看，这些结果表明，极向分辨率对于实现高保真度的陀螺动理学湍流代理建模起着核心作用。随着 Θ 降低而观察到的性能逐渐退化，有力地证明 GKFieldFlow 利用了具有物理意义的极向结构——包括气球模局域化、相位关系和垂直模耦合——来学习湍流吸引子的稳定表征。这项消融研究验证了模型的成功并非源于利用简单的统计相关性，而是有赖于捕捉完整三维场结构中蕴含的关键物理特征。

VIII. 讨论与未来工作

本文结果表明，GKFIELD-FLOW 所采用的时空神经网络架构结合了三维 U-Net 与时间模型，能够根据饱和陀螺动理学场数据准确预测湍流输运。本研究聚焦于一个有代表性的离子尺度算例，以验证其可行性。未来工作将对不同参数空间（如几何、碰撞性、 β等）及电磁学物理状态进行系统评估。就实际表现而言，对于这一测试算例，在相同物理时间区间内，该代理模型相较于 CGYRO 可减少 $\mathcal{O}(10^3)$ 的 GPU 资源消耗，同时保持连贯的场结构并准确再现通量统计。

除了在本文所述特定测试算例中的表现外，该模型设计有意采用模块化结构，便于进行多种自然扩展，下面将逐一介绍。

A. 扩展至动力学矩和其他陀螺动理学场

在本研究中，涨落的静电势 $\phi(\mathbf{r}\ t)$ 是唯一的场级输入，并以实部和虚部作为独立通道表示。不过，该架构很容易推广，以纳入非线性陀螺动理学模拟中通常计算的其他陀螺动理学输出。具体而言，密度、温度和平行流涨落等动力学矩（δn_s, δT_s, $\delta u_{\parallel,\ s}$），以及诸如 $A_\parallel$（在相关情况下还包括 $\delta B_\parallel$）等电磁场，同样都是定义在兼容时空网格上的复值三维量。

因此，这些可观测量可以作为额外的输入通道引入，而无需修改核心架构。从物理角度看，这种灵活性使我们能够系统地探索：获取日益丰富的相空间信息会如何影响输运预测、鲁棒性和泛化。尤其是，加入动力学矩可能为模型提供更直接的能量和粒子输运路径代理，从而

有可能改善外推表现。

B. 谱局域性及其对多尺度湍流的影响

本文考察的模拟对应于离子尺度湍流，其中非线性耦合在 k_y 空间中相对局域，包括带状流与主要湍流模态之间的相互作用。因此，只需适度的有效感受野深度即可实现准确的输运预测，且在副法线（k_y）方向上无需显式下采样。

这种情况并非普遍适用。在多尺度离子–电子湍流以及电子温度梯度主导的物理状态中，活跃谱带宽会显著拓宽，跨尺度相互作用也会更加突出。要高效表示这类动力学，可能需要扩展架构，在 k_y 中显式编码多分辨率结构，例如采用下采样–上采样路径或分层谱表示。重要的是，这些方法必须保持低-k_y 分量的保真度，因为这些分量通常通过带状流动力学，在调控输运方面发挥着不成比例的重要作用。

这些考量表明，针对单尺度离子湍流优化的架构选择可能无法直接迁移至多尺度物理状态；而当前框架则为以可控方式研究这些权衡提供了灵活的起点。

C. 迈向条件局部陀螺动理学代理模型

一项关键的长期目标是开发通用的局部陀螺动理学神经代理模型，使其能够在广泛的等离子体条件参数空间内进行插值。在确定合适的涨落场和矩通道集合后，可利用涵盖平衡几何和驱动参数（包括磁场位形塑造、安全因子、磁剪切以及归一化密度和温度梯度）的大型 CGYRO 模拟数据库来训练当前模型。

在这种设定下，可以将模拟描述符作为额外的条件输入提供给网络，使单个模型能够表示一族局域湍流状态。这样的条件代理模型将超越单一状态模拟，转而对局域陀螺动理学输运映射本身进行数据驱动近似。要严格评估其泛化能力，需在训练期间留出参数空间中的完整区域，从而量化模型的插值能力和有限外推能力。

D. 局限性

应当强调本研究的若干局限。首先，模型是在一组独立的离子尺度模拟上训练和评估的，这些模拟采用固定的物理假设，且参数范围有限。模型在该分布之外的表现，包括在不同几何构型或电磁状态下的表现，尚未得到评估。其次，输入数据取自统计饱和的湍流；模型处理瞬态阶段或状态转变的能力仍有待研究。最后，尽管模型捕捉到了与输运预测相关的相关性，但并未显式强制满足守恒定律，因此，其预测应被视为数据驱动近似，而非约化物理模型。

通过扩充训练数据集、丰富物理输入并纳入具有物理依据的归纳偏置来解决这些局限性，是未来工作的明确方向。

E. 展望

综合来看，这些拓展勾勒出一条发展路径：构建可直接处理高维陀螺动理学场数据、同时与底层物理紧密契合的神经代理模型。通过系统地提升物理丰富度、谱复杂度和参数覆盖范围，GKFieldFlow 框架为探究数据驱动输运建模在陀螺动理学湍流中的局限提供了一个可扩展的平台。

F. 架构的更广泛适用性

尽管本文提出的时空FieldFlow-Net 架构是针对陀螺动理学湍流开发并进行演示的，但它并非陀螺动理学湍流所专有，而是一种可复用的时空代理模型范式：由三维空间特征编码器、时间模块以及轻量级领域适配器组成，后者将内部潜在表示映射为具有物理意义的量。同一结构也适用于更广泛的一类偏微分方程支配的系统，其中（i）多通道场随局部时间演化而变化；（ii）所需输出对应的是聚合物理算子，而非完整的场重建。表III总结了这种可移植性。从这一角度看，GK-FieldFlow 是一种通用模板的陀螺动理学实例；实现可移植性只需更改输入通道语义和输出算子，无需改动架构本身。

例如流体湍流中的亚网格尺度建模，其中速度场或涡量场被映射为应力或耗散率；以及地球物理和气候

领域	输入通道 X	预测目标 y	用例／解读
陀螺动理学（聚变）	$\{\phi,\ A_\parallel,\ \delta n,\ \dots\}$	$\{Q_i,\ Q_e,\ \Gamma\}$	湍流输运代理模型；$\mathcal{O}(10^3)$ 更快的通量评估。
流体 / 计算流体力学 / 空气动力学	$\{\mathbf{u}\ \ \omega,\ \ p\}$	$\{\tau_{\mathrm{SGS}},\ \epsilon,\ \Pi\}$	亚网格闭合、耗散估计、降阶建模。
气候 / 全球气候模式物理	$\{T,\ q,\ \mathbf{u}\ \ \partial_z\theta\}$	加热/冷却，水汽趋势	快速参数化 全球气候模式物理的替代方案。
波 / 电磁学 / 光子学	$\{\mathbf{E},\ \mathbf{B}\ \ \psi\}$ (实数/复数)	包络/辐射源项	色散算子的替代模型 和能量传递率。
通用偏微分方程替代模型	$\mathbf{X}(t-T_c{:}t)$ 任意通道	$\mathcal{F}[\mathbf{X}]$ 算子定义的输出	模板适用于存在局部性 + 因果演化的情况。

表III：时空代理模型架构的领域无关映射。GKFieldFlow 是通用模板——三维空间编码、时间建模和特定领域的预测头——在陀螺动理学中的实现，而输入通道和物理算子会因应用而异。

建模，其中粗粒化通量或趋势取决于大气场或海洋场近期的演变；以及涉及复值电磁场或声场的基于波的系统，其中相位信息起着核心作用。在所有情况下，该架构都作为一种数据驱动的函数映射，将时空场数据映射为具有物理意义的聚合量。

与此同时，要成功应用于其他领域，需要针对具体领域选择输入通道、归一化方式和训练数据集；本文并未暗示该方法具有普适性。相反，本研究展示了一种通用建模策略，可直接从场级模拟数据中学习输运相关动力学，并可根据其他具有相似结构特征的物理情境进行调整。

附录A：架构详细规范

1. 用于空间特征提取的三维 U-Net编码器

对于每个时间切片 $\Phi(t)$，三维空间编码器通过一系列三维卷积提取湍流场中的空间结构，卷积采用小型立方卷积核（$n \times n \times n$），并结合沿（R、 Θ）方向的多级空间下采样。随着网络深度增加，特征通道数逐渐增多，而（R、 Θ）平面内的空间分辨率则逐步降低。在每个编码器层级，步幅卷积会沿（R、 Θ）方向执行下采样，使网络能够捕捉范围越来越广的空间结构，同时保持计算上的可行性。k_y 维不进行下采样，而是作为独立的谱索引贯穿所有编码器阶段。

每个分辨率层级都会生成相应的多尺度特征嵌入 E_ℓ，随后通过解码器中的跳跃连接加以复用。在每个层级中，采用带有归一化和非线性激活的三维残差卷积块，以促进稳定训练，并有效提取湍流场中的多尺度几何特征和谱特征。

a. 潜在表示。在最粗的空间分辨率下，对编码后的特征张量进行空间池化，并将其投影到紧凑的潜向量上，

$$f_t \in \mathbb{R}^{d_{\mathrm{lat}}}, \tag{A1}$$

它作为时间 t瞬时湍流状态的高层表示。潜在维度 d_{lat} 的选取旨在兼顾表征能力与计算效率。

这种设计使编码器深度能够随输入分辨率自然扩展：对于（R、 Θ）方向上空间分辨率更高的情况，可增加下采样阶段，在保持潜在表示规模适中的同时，使网络能够表示日益复杂的空间结构。

2. 时间TCN详述

a. TCN Input Sequence

对于每个以时间 t 结束的输入窗口，时间模块处理一组潜在表示，

$$\mathbf{F} = [f_{t-T_c+1}, \dots, f_t] \in \mathbb{R}^{B\times T_c\times d_{\mathrm{lat}}}, \tag{A2}$$

并将其作为时间卷积网络（TCN）的输入。

b. Temporal Projection and Dilated Residual Modeling

首先，通过学习得到的一维卷积投影，将潜在序列映射到内部时间特征空间，

$$d_{\mathrm{lat}} \ \longrightarrow\ d_{\mathrm{temp}}, \tag{A3}$$

用于为时间处理准备特征。随后，投影后的序列会输入一系列残差膨胀卷积块，这些卷积块遵循标准 TCN 设计原则 [21, 30]。

c. Receptive field for a dilated TCN

通常，对于多层因果膨胀 TCN，第 ℓ 层的膨胀因子按照几何递增的规律选取，

$$d_\ell = d_0\,\alpha^\ell, \qquad \alpha > 1, \tag{A4}$$

这使感受野能够随着网络深度呈指数级增长，同时保持计算效率。对于大小为 k 的卷积核，在索引 t 处应用的单个膨胀卷积可表示为

$$y_t = \sum_{j=0}^{k-1} w_j\, x_{t-j d_\ell}, \tag{A5}$$

其有效感受野为

$$R_{\text{eff}}^{(\ell)} = (k-1)\,d_\ell + 1. \tag{A6}$$

堆叠多个膨胀卷积层后，总感受野会随网络深度迅速扩大，使时间卷积网络能够捕捉离散快照之间的多尺度时间依赖关系，而无需依赖长序列模型。

d. Causality and Temporal Latent Representation

通过左填充卷积确保因果性，从而避免访问未来输入。时间卷积网络会生成一系列隐藏状态，

$$h_{1:T_c} = \mathrm{TCN}(\mathbf{F}), \tag{A7}$$

并从中提取一个经过时间聚合的潜在表示，

$$z_T = \mathcal{A}(h_{1:T_c})\,, \tag{A8}$$

其中 $\mathcal{A}(\cdot)$ 表示聚合算子。在实际应用中，该表示编码了与未来场与输运预测相关的短程时间依赖关系，同时不受长期相位演化的影响。

e. Temporal TCN for Latent Evolution

空间编码器为湍流场的每个时间切片生成一个潜向量 $f_t \in \mathbb{R}^{d_{\text{lat}}}$。为纳入时间动力学，这些潜向量会由时间卷积网络（TCN）进行处理。TCN 是一类一维架构，采用膨胀卷积来建模长程依赖关系，同时保持稳定的梯度行为[20, 21, 30, 31]。与循环模型相比，TCN 更具吸引力，因为它支持并行序列计算，并能灵活控制感受野。

3. 用于通量与场预测的双头实现

潜在状态 z_T 由两个预测头共享：

1. **通量头：** 一个用于生成多物种湍流输运的多层感知机

$$z_T \mapsto \widehat{\mathbf{F}} = [(Q_i, Q_e, \Gamma)_{t+1}, \ldots, (Q_i, Q_e, \Gamma)_{t+H}]$$

涵盖一个或多个预测时域 H。这会生成形状为 $[B, H, 3]$ 的张量。通量头仅依赖于经时间卷积网络演化的潜在表示，与完整的回旋动理学通量计算相比，计算成本更低。

2.**场演化头：** 一个轻量级卷积解码器，用于预测粗粒度的未来静电势 $\widehat{\ }\,\Phi(t+H)$，作为自回归滚动预测机制的一部分。

使用共享的时间卷积网络，可确保两个头都依赖于一致且具有因果结构的时间表示，同时保证预测绝不包含来自时间 $t' > t$ 的信息。

$\widehat{\ }$4. 用于预测 $\Phi(t+H)$ 的三维 U-Net 解码器

为重建未来的陀螺动理学势场，三维解码器通过 U-Net 风格的上采样路径，将经过时间聚合的潜在表示 z_T 映射回物理空间。首先，将潜向量重塑为与最深层编码器层级相适配的粗略空间特征图，随后通过一系列空间上采样阶段，逐步恢复 (R, θ) 方向上的分辨率。

在每个解码器阶段，上采样后的特征都会通过跳跃连接与对应的编码器激活融合，使较早层级中的精细尺度相位信息能够补充潜在状态所承载的日益全局化的表示。这种多尺度融合使解码器能够在预测场中重建大尺度结构和小尺度湍流特征。

解码器的最后一层会生成未来时间偏移量为$\backsim t + H$ 时的回旋动力学势复数值预测，得到 $\Phi(t+H)$，其复数实部和虚部定义在原始空间网格上。

a. 上采样策略。 解码器中的空间上采样采用确定性插值，随后进行卷积细化，而不是使用学习型转置卷积。这一选择既出于数值稳定性的考虑，也出于物理保真度的考虑。众所周知，转置卷积会因卷积核重叠不均匀而引入依赖网格的伪影，这些伪影可能表现为重建结果中的虚假小尺度结构和不符合物理规律的高波数成分

场。相比之下，基于插值的上采样能够平滑且条件良好地提高空间分辨率，确保在进行跳跃连接融合之前与编码器特征保持一致对齐。这种方法尤其适用于陀螺动理学湍流，因为上采样仅需在选定的空间维度中进行，而其他方向的谱模则必须保持不变。

附录B：相位相干性诊断

为量化代理模型生成的预测静电势 $\phi(\mathbf{r}\ t)$ 与CGYRO真实势 $\phi(\mathbf{r}\ t)$ 之间的相似性，我们采用湍流分析中广泛使用的两种互补诊断方法：(i) 按 k_y 分辨的相位相干性度量，以及 (ii) 对角度平均涨落谱 $\langle|\phi|^2\rangle_{r,\theta}(k_y)$ 的比较（见图 7）。在以下所有表达式中，我们将 ϕ 视为复场，$\phi = \phi_{\mathrm{real}} + i\,\phi_{\mathrm{imag}}$，其直接由 CGYRO 的傅里叶实部和虚部分量构造而成。

对于每个环向模 k_y，我们计算预测值与真实值之间的局部相位差：

$$\Delta\varphi(\mathbf{x}, k_y) = \arg\left[\hat{\phi}(\mathbf{x}, k_y)\,\phi^*(\mathbf{x}, k_y)\right], \qquad \text{(B1)}$$

其中，$\mathbf{x} \equiv (r, \theta)$ 表示其余空间索引。相位完全对齐的预测在每处都得到 $\Delta\varphi = 0$，而相位随机误差则会在 $[-\pi, \pi]$ 上形成均匀分布。

衡量相位相似度的一种稳健标量是圆形相干性，其定义为空间和集合实现上的复数平均值的模：

$$C_\varphi(k_y) = \left| \left\langle e^{\,i\,\Delta\varphi(\mathbf{x}, k_y)} \right\rangle_{\mathbf{x},\,\mathrm{ens}} \right|. \qquad \text{(B2)}$$

该量满足 $0 \le C_\varphi \le 1$。$C_\varphi \approx 1$ 的值表明，代理模型在该 k_y下重现了正确的湍流相位结构；对于陀螺动理学湍流而言，这是一项尤其严格的要求，因为径向延展的气球模本征结构和非线性相位对齐会驱动输运 [32, 33]。

附录 C：损失函数

训练目标由多个互补项构成，旨在平衡瞬时精度与短时域稳定性。

a. 通量预测损失。对于每个预测时域 τ_h，对预测的输运通量应用均方误差（MSE）损失，

$$\mathcal{L}_{\mathrm{flux}} = \frac{1}{H}\sum_{h=1}^{H} \left\| \widehat{\mathbf{Q}}(t+\tau_h) - \mathbf{Q}(t+\tau_h) \right\|_2^2,$$

其中 $\mathbf{Q}_{\ i}, (Q_{\ e} Q$ 表示目标通量向量。 fl

b. 场重建损失。为提高短期场演化预测的准确性，对下一时间步的预测回旋动力学势应用均方误差（MSE）损失，

$$\mathcal{L}_{\Phi} = \left\| \widehat{\Phi}(t+1) - \Phi(t+1) \right\|_2^2.$$

c. 滚动一致性损失。为促进自主多步预测的稳定性，引入一种可选的辅助损失。在长度为 K 的滚动窗口内，该项惩罚预测量与参考量之间的偏差，

$$\mathcal{L}_{\mathrm{roll}} = \lambda_{\mathrm{roll}} \left[\frac{1}{K}\sum_{k=1}^{K} \left\| \widehat{\mathbf{Q}}(t+k) - \mathbf{Q}(t+k) \right\|_2^2 + \alpha_\Phi\, \frac{1}{K}\sum_{k=1}^{K} \left\| \widehat{\Phi}(t+k) - \Phi(t+k) \right\|_2^2 \right], \qquad \text{(C1)}$$

其中，预测值会在整个滚动预测时域内递归计算。该项在保持单步精度的同时，提升了自回归的鲁棒性。

d. 组合目标函数。 训练期间最小化的总损失为

$$\mathcal{L} = \mathcal{L}_{\mathrm{flux}} + \alpha_\Phi\,\mathcal{L}_{\Phi} + \mathcal{L}_{\mathrm{roll}},$$

相对权重 α_Φ 和 λ_{roll} 按实验分别选定。

参考文献

[1] Horton W 1999 *Rev. Mod. Phys.* **71** 735[2] Bravenec R V、Candy J、Barnes M 和 Holland C，2011 *Physics of Plasmas* **18** 122505[3] Kotschenreuther M *et al.* 2019 *Nucl. Fusion* **59** 096001 Howard N T、[4] *et al.* 2016 *Nucl.* Holland C、White A E *Fusion* **56** 014004[5] Mandell N、Dorland W 和 Landreman M 2018 *J. Plasma Phys.* **84** 905840108

[6]Maeyama S 和 Watanabe T H 2021 *Phys. Rev. Lett.* **126** 165002[7]Staebler G M、Kinsey J E 和 Waltz R E 2007 *Phys.Plasmas* **14** 055909[8]Bourdelle C、Garbet X、Imbeaux F、Casati A、Dubuit N、Guirlet R 和 Parisot T 2007 *Physics of Plasmas***14** 112501 ISSN 1070-664XURL https://doi.org/10. 1063/1.2800869

[9]Ashourvan A 和 Candy J 2024 *Phys. Rev. Lett.***132**(20) 205101 网址 https://link.aps.org/doi/10.1103 132 205101 /PhysRevLett. 。Groebner R J [10] *et al.* 2018 *Nucl. Fusion* **58** 112006[11] Shi E L、Hammett G W、Stoltzfus-Dueck T 和 Hakim A 2019 *Physics of Plasmas* **26** 012307[12] Ma H、Zhang Y、Thuerey N、Hu X 和 Haidn O J 2021 [13]Bao T、*arXiv preprint arXiv:2106.09301* Chen S、Johnson T T、Givi P、Sammak S 和 Jia X 2022 用于湍流时空超分辨率的物理引导神经网络 *Proc. 38th 2022)* 卷 180 *Conf. on Uncertainty in Artificial Intelligence (UAI* 页 118–128[14] Clavier B、Zarzoso D、del Castillo-Negrete D 和 Fr´enod E 2025 *Physical Review E* **111** L013202 用于等离子体湍流的生成式人工智能代理模型可加速输运模拟。[15] Boffi N M 和 Vanden-Eijnden E 2023 *Machine Learning: Science and Technology* **4** 035012网址 https://doi.org/10.1088/2632-2153/ace2aa[16] Cao Y、Zhang F、Liu W、Neiser T、Meneghini O、Fuller L、Smith S、Nazikian R、Sammuli B 和 Yu R 2025 Tglf-sinn：用于加速聚变中湍流输运建模的深度学习代理模型（ *Preprint* 2509 07024 2509 07024 .）网址 https://arxiv.org/abs/ 。[17]van de Plassche K L、Citrin J、Bourdelle C、Camenen Y、Casson F J、Dagnelie V I、Felici F、Ho A、Van Mul- ders S 和 Contributors J 2020 *Physics of Plasmas***27**022310 ISSN 1070-664X 网址 https://doi.org/10. 1063/1.5134126[18] Ji S、Xu W、Yang M 和 Yu K 2013 *IEEE Transactions on Pattern Analysis and Machine Intelligence* **35** 221– 231

[19] Ronneberger O、Fischer P 和 Brox T，2015，《U-net：用于生物医学图像分割的卷积网络》*Medical Image Computing and Computer-Assisted Intervention (MICCAI)*（Springer），第 234–241 页[20] Lea C、Flynn M、Vidal R、Reiter A 和 Hager G，2017，《用于动作分割与检测的时间卷积网络》*IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* 1003 1012 第 – 页 Bai S、Kolter J Z 和 [21] Koltun V 2018 *arXiv:1803.01271*[22]Kingma D P 和 Ba J 2014 *arXiv preprint arXiv:1412.6980* 1412 网址 https://arxiv.org/abs/ . 6980[23]Landau L D 和 Lifshitz E M 1980 *Statistical Physics*（Butterworth-Heinemann）[24]Diamond P H、Itoh S I、Itoh K 和 Hahm T S，2005 *Plasma Physics and Controlled Fusion* **47**R35–R161[25] Hatch D R、Terry P W、Jenko F、Merz F 和 Pueschel M J 2011 *Physical Review Letters* **106** 115003[26] Told D、Jenko F、TenBarge J M、Howes G G 和 Ham- mett G W 2015 *Phys. Rev. Lett.* **115** 025003 Candy J 和 Belli E A [27] 2016 *J. Comput. Phys.* **324** 73–93[28]Mohan A T 和 Gaitonde D V，2018，《一种基于深度学习的方法：使用 LSTM神经网络对湍流进行降阶建模与控制》（1804 09269 *Preprint* 1804 09269 .）网址 https://arxiv.org/abs/ .[29]Mishra S 和 Molinaro R，2023，《物理信息神经网络（PINN）逼近偏微分方程时泛化误差的估计》（*Preprint* 2006.16144）网址 https://arxiv.org/abs/ 2006 16144 . [30] van den Oord A、Dieleman S *et al.* 2016 [31] Yu F 和 Koltun *arXiv:1609.03499* V，2016，《通过膨胀卷积实现多尺度上下文聚合》 *ICLR* [32] Barnes M 和 Dorland W 2010 *Phys. Plasmas* **17** 032106 Waltz R E、[33] Kerbel G D 和 Milovich J 1994 *Phys. Plasmas* **1** 2229