

文章编号: 1002-1582(2026)02-0203-08

基于波前预测模型的波前校正方法

马玉磊^{1*}, 杜广鑫²

(1. 新乡学院 计算机与信息工程学院, 河南 新乡 453000)

(2. 中国人民解放军32096部队, 湖北 武汉 430074)

摘 要: 针对自适应光学中波前传感器与波前校正之间的时延问题, 提出一种基于波前预测模型的自适应光学波前实时校正方法。波前预测模型由两个并行分支构成, 第一个分支基于波前时间序列计算差分波前序列以得到大气湍流的时域动态演化信息, 将其传入长短期记忆网络提取大气湍流演化的动态特征; 第二个分支将波前时间序列传入增强的Transformer编码器提取波前序列的时间域依赖性, 并使用多尺度卷积层提取每个波前系数的空间域特征, 从而得到包含畸变波前时空域信息的特征。最终, 通过交叉注意力机制动态地从第一个分支输出特征中筛选与当前波前预测最相关的动态特征, 基于动态特征与Transformer编码特征的融合信息进行波前预测。仿真结果表明, 在强、中与弱湍流下, 所提波前预测模型的均方根误差分别比次优模型减少43.8%、43.9%和57.9%。

关 键 词: 自适应光学; 大气湍流; 光束传播; 深度学习; 序列模型; 波前校正

中图分类号: TP394.1; TH691.9

文献标识码: A

Wavefront correction method based on wavefront prediction model

MA Yulei^{1*}, DU Guangxin²

(1. Department of Computer and Information Engineering, Xinxiang University, Xinxiang 453000, China)

(2. Chinese People's Liberation Army 32096 Unit, Wuhan 430074, China)

Abstract: Aiming at the problem of time delay between wavefront sensor and wavefront correction in adaptive optics, a wavefront real-time correction method based on wavefront prediction model for adaptive optics is proposed. The wavefront prediction model consists of two parallel branches, in the first branch, the difference wavefront sequence is computed based on wavefront time sequence to generate the temporal dynamic evolutionary information of the atmospheric turbulence, and it is delivered to long short term memory network to extract the dynamic features of atmospheric turbulence evolution. In the second branch, the wavefront time sequence is delivered to the enhanced Transformer encoder to extract the temporal dependency of the time sequence, and a multi-scale convolutional neural layer is introduced to extract the spatial features of each wavefront Zernike coefficient, to generate features including temporal and spatial information of the aberration wavefronts. Finally, the dynamic features most relevant to current wavefront prediction are selected from the features come from the first branch by using of cross-attention mechanism, and the future wavefront are predicted based on the information with combination of dynamic features and Transformer encoded features. Simulation results show that under the conditions of strong, moderate and weak turbulent atmospheric, the root mean square error of the proposed wavefront prediction model decreases by 43.8%, 43.9% and 57.9% respectively compared to the second-best method.

Keywords: adaptive optics; atmospheric turbulence; beam propagation; deeplearning; sequence model; wave-front correction

收稿日期: 2025-12-01; 收到修改稿日期: 2026-01-09

基金项目: 河南省科技厅重点研发与推广专项(科技攻关)项目(212102210405); 新乡学院教育教学改革研究与实践项目成果(31)

作者简介: 马玉磊(1982—), 男, 副教授, 从事计算机网络研究。mayulei8219@163.com

杜广鑫(1996—), 男, 助理工程师, 从事大数据分析与信息传播研究。

* 通讯作者: mayulei8219@163.com

0 引 言

自适应光学通过校正大气湍流等因素引起的波前失真,可提高天文观测、激光传输以及光学成像的效果^[1,2]。在自适应光学中,从波前传感器检测到波前校正具有 2, 3 帧的时延^[3],因此传统校正方法难以实时校正当前波前^[4]。此外,大气湍流具有动态演化特性^[5],这对波前校正技术的准确性与动态适应能力均提出了极高的要求^[6]。

早期研究人员通过基于状态空间模型的离散时间线性二次高斯控制器^[7]与卡尔曼滤波器^[8,9]建模大气湍流引发的波前畸变,通过提前预测与校正未来的畸变波前来解决自适应光学的时延问题。虽然此类方法成功证明通过波前预测能实时校正畸变波前,但它们不仅需要大气湍流的先验知识,而且需要掌握调节控制器或滤波器的领域知识,实现难度较大^[10]。

近年来,研究人员使用深度学习模型学习历史畸变波前到未来波前的映射关系,实现了长足的进步^[11-12]。目前,使用深度学习的波前预测方法主要采用神经网络(Back Propagation Neural Network, BPNN)和长短期记忆神经网络(long Short-Term Memory, LSTM)两种经典模型^[13]实现。文献[14]提出一种残差学习与特征融合的 BPNN,该网络利用较少的历史波前数据即可将波前预测误差降低约一半。文献[15]使用 U-形网络(U-shaped Network, U-Net)作为波前预测模型,能成功预测未来最多 8 帧的波前。基于 BPNN 的波前预测^[14,15]主要利用 BPNN 学习历史波前的空间信息,并建模从历史波前序列到未来波前序列的映射关系,以预测未来波前。然而, BPNN 对时序依赖关系的建模能力不足,无法充分利用波前序列的时间域信息。

LSTM 是一种经典的时间序列模型,对局部依赖性的建模能力较强,同时具备一定的长程依赖关系建模能力,在波前预测任务中得以广泛应用^[16]。文献[17]将波前从高维电压空间转换至低维 Zernike 系数空间,将历史波前的 Zernike 系数传入 LSTM 进行预测,有效降低了数据维数,并提高了波前预测准确率。但 LSTM 的长程依赖关系建模能力不足且对波前相位空间特征的提取能力不足,导致此方法的预测性能受限。为了提升 LSTM 的波前预测性能,文献[18]提出一种基于注意力 LSTM (Attention LSTM, AtLSTM) 的波前预测方法,此方法利用注意力机制聚焦关键的历史波前帧信息,进一步提高了波前预测的准确性。文献[19]将卷积神经网络与 LSTM 结合,利用卷积网络捕获每个波前帧的空间信息,利用

LSTM 捕获历史波前的时域信息,实现了良好的性能。然而该方法属于高度结构化的拉盖尔-高斯光束波前预测法,难以用于非结构化的随机畸变的波前。尽管上述方法^[17-19]利用 LSTM 的序列建模能力实现了较准确的波前预测性能,但 LSTM 对序列短距离连续性变化模式的捕捉能力较强,但对长程依赖关系的捕捉能力有限,导致基于 LSTM 的波前预测精度不佳。

为降低基于深度学习的波前预测误差,结合 LSTM、Transformer 与交叉注意力机制提出新的波前预测模型(Wavefront Prediction Model, WFPM)。此模型使用 Transformer 编码器提取波前序列中各波前帧之间的长程依赖关系。基于历史波前序列构建差分波前序列,得到波前畸变的动态变化信息,使用对短距离连续性变化模式建模能力更强的 LSTM 提取波前畸变的动态演化信息,以提升模型对动态大气湍流的自适应能力。利用交叉注意力机制从动态演化特征中自适应地筛选与当前波前预测最相关的动态特性,并与 Transformer 编码特征进行动态融合。WFPM 模型对波前历史序列所隐含的时空域信息与大气湍流动态演化信息进行全面、系统性地建模,以期提升不同大气湍流下波前预测的准确性与动态适应能力。

1 系统模型

1.1 波前模型

为了降低计算复杂度^[17],本文使用 Zernike 系数表征每个波前帧。大气湍流会导致传播光束的波前发生畸变,可通过 Zernike 多项式^[20]建模波前传感器检测的波前

$$\varphi_t = \sum_j^m C_{(t,j)} Z_{(t,j)} = C_t Z_t \quad (1)$$

式中, m 为 Zernike 多项式项数; $Z_{t,j}$ 为 t 时刻第 j 项 Zernike 多项式; $C_{(t,j)}$ 为 t 时刻第 j 项 Zernike 多项式的 Zernike 系数; C_t 为时刻 t 的 Zernike 系数向量; Z_t 为时刻 t 的 Zernike 多项式向量。任意时刻的畸变波前相位可表示为 Zernike 多项式与 Zernike 系数的线性组合。Zernike 多项式第 1 项为平移项,第 2、3 项为 X、Y 方向的波前倾斜,第 4 项为离焦,第 5 与 6 项为像散,第 7 至 8 项为彗差,第 9 项为球差,第 10 至 16 项为高阶相差。

图 1 (a) 所示为不同湍流下的 Zernike 系数值,望远镜口径为 1m,波长为 550nm,弱湍流、中湍流和强湍流的弗里德 (Fried) 参数 r_0 依次等于 20、10 和 5cm。从图 1 (a) 来看,不同湍流强度的 Zernike 系数存在显著的差异,其中第 1 项 Zernike 系数与波

前畸变无关,因此使用第2至第16项的Zernike系数作为波前特征。图1(b)、(d)分别为弱湍流、中湍流与强湍流下的波前相位分布图,由图可知,不同强度湍流导致的波前畸变存在显著差异。




图1 波前畸变实例图

1.2 基于波前预测的波前校正方法

图2所示为基于波前预测的波前校正流程图。激光器发出的光束在大气中传播,大气湍流引起波前发生畸变。波前传感器将畸变波前的电压数据传至计算机,计算机将当前时刻及之前 $N-1$ 个时刻的Zernike向量组成一个Zernike系数序列传入WFPM模型。WFPM模型预测 $t+k$ 时刻的Zernike系数向量,并使用变形镜对预测的波前进行提前校正。




图2 基于波前预测的波前校正系统

2 WFPM模型设计

从图1(a)可以看出,Zernike系数向量包含畸变波前的空间特征,而Zernike系数序列包含畸变波前随时间变化的动态信息。因此需全面、系统性地捕捉Zernike系数在时间域与空间域的特征,才能提高波前预测的精度。

图3所示为WFPM模型的结构图。WFPM模型由两个并行分支构成,第一个分支基于波前时间序列得到差分序列,以得到大气湍流的时域动态演化信息,将其传入长短期记忆网络提取大气湍流演化的动态特征。第二个分支将波前序列传入增强的

Transformer编码器建模波前序列的时间域依赖性,并使用多尺度卷积层提取每个波前Zernike系数的空间域特征,以得到包含畸变波前时空域信息的特征。全局信息融合模块通过交叉注意力机制,自适应地从第一个分支输出特征中筛选与当前波前预测最相关的动态特征,将所选特征与Transformer编码特征融合。最终,全连接层对融合信息进行回归,预测时刻 $t+k$ 的波前Zernike系数向量。




图3 WFPM模型的结构图

2.1 数据处理

将Zernike系数历史序列表示为

$$C = [C_{t-N+1}, C_{t-N+2}, \dots, C_t] \quad (2)$$

式中, C_i 为时刻 i 的Zernike系数; N 为历史序列长度; t 为当前时刻。

为建模大气湍流的动态演化特性,计算Zernike系数的差分向量作为补充信息。差分Zernike系数历史序列定义为

$$\Delta C = [\Delta C_{t-N+1}, \Delta C_{t-N+2}, \dots, \Delta C_t] \quad (3)$$

$$\Delta C_i = \begin{cases} C_i, & i = 1 \\ C_i - C_{i-1}, & i > 1 \end{cases} \quad (4)$$

式中, ΔC_i 为时刻 i 的差分Zernike系数。

2.2 LSTM网络

差分Zernike系数历史序列输入LSTM网络,LSTM网络对序列的短程依赖性与局部时序特征进行提取。图4展示了LSTM单元的数据流动方向。




图4 LSTM单元数据流动示意图

图4中LSTM单元的数据流动可定义为以下的方程组

$$\begin{cases} i_t = \sigma(h_{t-1} \cdot W_{hi} + \Delta C_t \cdot W_{xi} + b_i) \\ f_t = \sigma(h_{t-1} \cdot W_{hf} + \Delta C_t \cdot W_{xf} + b_f) \\ o_t = \sigma(h_{t-1} \cdot W_{ho} + \Delta C_t \cdot W_{xo} + b_o) \\ c'_t = \tanh(h_{t-1} \cdot W_{hc} + \Delta C_t \cdot W_{xc} + b_c) \\ c_t = i_t \cdot c'_t + f_t \cdot c_{t-1} \\ h_t = o_t \cdot \tanh(c_t) \end{cases} \quad (5)$$

式中, i_t 、 f_t 、 o_t 、 c_t 、 h_t 和 c'_t 分别为时间步 t 的输入门、遗忘门、输出门、单元状态、隐藏状态和候选单元状态, $\sigma()$ 为 Sigmoid 激活函数, $\tanh()$ 为双曲正切函数, h_{t-1} 为时间步 $t-1$ 的隐藏状态, c_{t-1} 为时间步 $t-1$ 的单元状态, W_{hi} 、 W_{xi} 、 W_{hf} 、 W_{xf} 、 W_{ho} 、 W_{xo} 、 W_{hc} 与 W_{xc} 为 LSTM 的权重矩阵集, b_i 、 b_f 、 b_o 与 b_c 为 LSTM 的偏置向量集。

2.3 Transformer 编码器

Zernike 系数历史序列输入经过正弦余弦位置编码^[21]后传入 Transformer 编码器, Transformer 编码器依次包含多头自注意力、层标准化、多尺度卷积层与层标准化四个模块, 并且通过两个残差连接保障网络的梯度流动。自注意力机制通过计算序列中各元素与其它元素间的相关性来捕捉序列中的全局依赖关系。图 5 展示了多头自注意力机制的计算流程。




图 5 Transformer 多头自注意力机制计算流程图

自注意力机制对输入序列 C 进行不同的线性变换得到三个向量, 分别为查询向量 Q 、键向量 K 与值向量 V , W^Q 、 W^K 与 W^V 为三个线性变换的权重矩阵。每个自注意力头通过计算 Q 与 K 之间的相似度来调节每个元素的表示 (如图 5 中右侧部分所示), 计算方法为

$$A_{\text{self}}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_K}}\right)V \quad (6)$$

式中, d_K 为 K 的维度, $\text{softmax}()$ 为 Softmax 函数。该式计算序列中各元素的注意力权重, 通过 Softmax 函数对权重进行归一化, 再与值向量 V 进行加权求和得到包含注意力的表示。

第 j 个自注意力头的输出为

$$g_j = A_{\text{self}}(QW_j^Q, KW_j^K, VW_j^V) \quad (7)$$

式中, W_j^Q 、 W_j^K 与 W_j^V 分别为第 j 个自注意力头的查询权重、键权重与值权重。

多头自注意力模块的输出为

$$A_{\text{MH}}(h) = \text{concat}(g_1, g_2, \dots, g_M)W^O \quad (8)$$

式中, M 为注意力头数; $\text{concat}()$ 为特征拼接操作; W^O 为输出权重。

多头自注意力模块的输出与输入相加以构成残差连接, 再进行层标准化处理。然后, 通过多尺度卷积层对每个 Zernike 系数向量的空间特征进行深入提取。图 6 所示为多尺度卷积层的结构图。该网络由 4 个并行分支构成, 第 1 分支通过 1×1 卷积捕捉通道间的线性关系, 第 2 分支通过 3×1 卷积捕捉中感受野的局部特征, 第 3 分支通过 5×1 卷积捕捉更大感受野的全局, 第 4 分支通过最大池化缓解过拟合。每个卷积之后使用线性整流单元 (Rectified Linear Unit, ReLU) 函数对系数特征向量进行非线性投影, 以增强模型的非线性拟合能力。将 4 个分支提取的特征拼接成多尺度卷积特征, 该特征包含每个 Zernike 系数向量的多尺度局部模式。最终使用 1×1 卷积将多尺度卷积特征的维度还原成输入维度。




图 6 多尺度卷积层的结构图

2.4 全局信息融合与波前预测

图 7 所示为全局信息融合模块与预测模块的流程图。首先计算系数序列特征 h' 与动态序列特征 h 之间的交叉注意力, 从动态序列中筛选对当前时刻预测重要的动态信息。动态信息经过全连接层整合后与 h' 拼接, 传入全连接层输出预测的波前系数向量。

对系数序列 h' 与动态序列 h 进行交叉注意力和全连接处理, 可表示为

$$h'' = \text{Att}(h, h') \cdot W_a + b_a \quad (9)$$

式中, W_a 与 b_a 分别为注意力机制后全连接层的权重与偏置, $\text{Att}()$ 为交叉注意力机制。




图7 全局信息融合模块与预测的流程图

交叉注意力机制 $Att()$ 包含两个主要步骤:

步骤1、将动态序列特征 h 线性投影为键矩阵和值矩阵, 将序列特征 h' 投影为查询矩阵

$$\begin{cases} Q_{CA} = f_Q(h') \\ K_{CA} = f_K(h) \\ V_{CA} = f_V(h) \end{cases} \quad (10)$$

式中, $f_Q()$ 、 $f_K()$ 和 $f_V()$ 为可学习投影矩阵。

步骤2、使用查询矩阵 Q_{CA} 寻找 h 中对当前时刻波前预测有用的信息, 计算方法为

$$h_a = \text{softmax}\left(\frac{Q_{CA} K_{CA}^T}{\sqrt{D_Q}}\right) V_{CA} \quad (11)$$

式中, h_a 表示 h 中所包含与当前时刻波前预测相关性高的动态信息, D_Q 为 Q_{CA} 的维度。

将动态信息与波前序列特征拼接后经过全连接层输出预测的波前系数向量 C'_{t+k}

$$C'_{t+k} = \text{concat}(h_a, h') \cdot W_y + b_y \quad (12)$$

式中, W_y 与 b_y 分别为全连接层的权重与偏置。

2.5 损失函数定义

使用均方误差 (Mean Squared Error, MSE) 作为 WFPM 模型训练的损失函数

$$\ell = \frac{1}{N_{\text{train}}} \sum_{i=1}^{N_{\text{min}}} \|C_{t_i+k} - C'_{t_i+k}\|^2 \quad (13)$$

式中, C_{t_i+k} 与 C'_{t_i+k} 分别为时刻 t_i+k 真实与预测的波前 Zernike 系数向量。

3 仿真与结果分析

3.1 仿真建立

采用文献[22]的方法建立 Matlab 仿真模型, 模拟一个典型的地基天文望远镜观测场景, 如图8所示。系统由太空中的点光源、大气相位屏与波前传感器构成, 点光源从太空发出的光线经过三个相位屏后到达地面的波前传感器, 三个冯·卡门统计特性的相位屏高度分别为 10、5 与 0 (km), 用以模拟不同高度大气湍流引起的波前相位畸变。




图8 地基望远镜仿真图

表1所示为仿真系统的参数设置。根据泰勒假设^[23], 可使用风吹动三个相位屏随时间演化, 以模拟大气湍流随时间演化的特性, 10、5与0 (km) 处的风速范围分别为 15 ± 1.5 、 10 ± 1 与 5 ± 0.5 (m/s), 从 $(0, 2\pi]$ 弧度范围内随机采样风向。在大气相干长度 $r_0=10\text{cm}$ 条件下生成 5000 个波前用于训练, 然后在 r_0 等于 5、10 与 20 (cm) 条件下分别生成 1000 个波前用于测试, 以评估模型对不同湍流强度的泛化能力与鲁棒性。对全部 Zernike 系数进行归一化处理, 以增强模型训练与测试的稳定性。

表1 仿真系统参数设置

参数	值
望远镜直径/m	4
波前网格尺寸	128×128
光波长/nm	550
采样频率/Hz	800
大气相干长度/cm	5, 10, 20

3.2 参数与对比方法

在一台工作站上进行数据处理与模型搭建工作。工作站的配置如下: Intel i9-14900K CPU, 32 GB Ram, NVIDIA RTX4090 显卡, 操作系统为 Windows 11。开发平台采用 Python 3.10, 采用 PyTorch 2.0 和 Hugging Face 库实现深度学习模型, 采用 Matlab 2023b 作为仿真平台。

为了评估所提方法的性能, 选择 LSTM^[17]、AtLSTM^[18] 与 Transformer^[21] 模型与本文模型进行对比。四种模型均在相同的训练集与测试集上分别进行训练与测试。使用自适应矩估计 (Adaptive Moment Estimation, Adam) 优化器对四种模型的参数进行优化, 学习率设为 0.0003, 批尺寸为 32, 最大训练轮次为 150。LSTM 与 AtLSTM 的超参数设为原文的参数。使用网格搜索寻找 Transformer 与 WFPM 模型的参数, Transformer 模型的注意力头数设为 6, 编码器层数为 2, 全连接层包含两个线性层, 第一层节点数为 32, 第 2 层为 15; WFPM 的 LSTM 隐藏层数为 2, 注意力头数为 6, 编码器层数为 2, 全连接网络包含两个线性层, 第一层节点数为 48, 第 2 层为 15。

3.3 模型训练

从训练集第 15 个波前开始将前 15 个波前输入模型, 预测未来第 3 个波前。图 9 所示为 LSTM、AtLSTM 与 Transformer 模型与 WFPM 模型训练的损失曲线。从图中可以看出, 4 个模型的损失皆随着轮数的增加呈现平滑的下降趋势。由于 LSTM 参数量最少, 因此仅需约 25 轮可达到稳定值, AtLSTM、Transformer 与 WFPM 大约需 80 轮方可趋于稳定。比较图中 4 个损失曲线可知, LSTM 的复杂度低但拟合能力弱, 故损失值较大, 而 AtLSTM、Transformer 与 WFPM 均成功收敛。




图 9 模型损失曲线

3.4 模型测试

在模型测试过程中, 分别利用真实波前与预测波前的 Zernike 系数值重建波前相位, 然后计算实际波前与预测波前之间相位的均方根误差 (Root Mean Square, RMS) [22]。图 10 所示为三种湍流强度大气条件下, 各模型前 500 个连续波前的 RMS 对比结果。从图 10 (a) 可以看出, LSTM

的 RMS 较高, 而 WFPM 模型的 RMS 较低。此外, 各模型的 RMS 均在一个较稳定的范围内波动, 说明所有模型在弱湍流下的波前预测稳定性较高。

从图 10 (b) 可以看出, 随着湍流强度升高, 波前序列中连续波前之间的差异增大, 而 LSTM 对非平稳序列的建模能力较弱, 因此 LSTM 的 RMS 显著升高。而 AtLSTM 利用注意力聚焦关键的历史波前帧与波前空间信息, 有效增强了 LSTM 的波前预测性能, 其 RMS 显著小于 LSTM。WFPM 模型在中湍流下的 RMS 较弱湍流有所上升, 但依然低于其它三种模型, 主要原因在于 WFPM 模型利用 Transformer 的多头自注意力机制捕捉波前序列的时间域依赖性, 而该机制对高离散、非平稳序列的性能依然较好, 因此能捕捉剧烈变化的时序信息。

从图 10 (c) 可以看出, 在强湍流大气条件下, LSTM 与 AtLSTM 的 RMS 均显著升高, 而 Transformer 模型的 RMS 成为强湍流下的次优模型, 表明即使为 LSTM 模型增加时间域与空间域的注意力机制, 也无法克服强湍流下的波前剧烈变化问题。而 Transformer 模型的多头自注意力机制在强湍流下展现出一定的优势, 通过建模全局波前帧之间的依赖关系, 实现了较小的 RMS。在 Transformer 模型的基础上, WFPM 对 Transformer 的前馈网络进行了增强, 提升其空间特征提取能力, 并引入 LSTM 分支对差分波前序列进行建模, 以提取大气湍流的动态信息。综上所述, WFPM 通过全面捕捉波前序列的时空域信息与大气湍流的动态演化信息, 有效提升了波前预测的精度与稳定性。




图 10 不同湍流下的 RMS 结果

表 2 所示为不同湍流下各模型的 RMS 均值与标准偏差 (Standard Deviation, STD)。表 2 显示, Transformer 模型在强湍流下的性能优于 LSTM, 可证明 Transformer 对非稳态、非连续性序列的建模能力较强。相较于其它三种预测模型, WFPM 通过增强 Transformer 分支对波前序列时空域特征进行有效建模, 并通过 LSTM 对差分波前序列进行建模, 在不同湍流强度下均取得了最

低的预测 RMS 与 STD。在弱湍流下, WFPM 的 RMS 分别比 LSTM、AtLSTM 和 Transformer 减少 72.2%、57.9% 和 63.8%; 在中湍流下, WFPM 的 RMS 分别比 LSTM、AtLSTM 和 Transformer 减少 71.5%、43.9% 和 59.4%; 在强湍流下, WFPM 的 RMS 分别比 LSTM、AtLSTM 和 Transformer 减少 55.4%、47.9% 和 43.8%。

表 2 不同湍流下的量化性能

项目强度	模型	均方根 RMS/rad	标准偏差 STD/rad
弱湍流	LSTM	0.1812	0.0328
	AtLSTM	0.1195	0.0158
	Transformer	0.1391	0.0177
	WFPM	0.0503	0.0058
中湍流	LSTM	0.3315	0.0647
	AtLSTM	0.1682	0.0376
	Transformer	0.2324	0.0546
	WFPM	0.0944	0.0097
强湍流	LSTM	0.3392	0.0324
	AtLSTM	0.2901	0.0215
	Transformer	0.2689	0.0206
	WFPM	0.1512	0.0185

3.5 消融分析

为验证 WFPM 模型各模块的有效性，对其进行消融分析。消融分析包含以下变体模型：从 WFPM 中移除 LSTM 分支和全局特征融合模块，简称为 WFPM1；使用原 Transformer 替换 WFPM 中的增强 Transformer，简称为 WFPM2；使用特征拼接替换 WFPM 的全局融合模块，简称为 WFPM3。所有变体模型均使用相同的训练集与测试集。

表 3 所示为各模型的消融分析结果。将 WFPM1 与 WFPM 对比可看出，在弱、中与强湍流下，WFPM 的 RMS 分别比 WFPM1 降低了 51.3%、39.0% 与 36.7%。这表明移除 WFPM 中的 LSTM 分支会导致 RMS 升高，可知 LSTM 能捕捉大气湍流的动态演化信息，模型能有效利用大气湍流的动态信息提升波前预测精度，这对增强模型对动态大气环境的适应能力极为重要。将 WFPM2 与 WFPM 对比可看出，在弱、中与强湍流下，WFPM 的 RMS 分别比 WFPM2 降低了 37.4%、23.4% 与 30.2%。这表明使用原 Transformer 的前馈网络替换 WFPM 的多尺度卷积层会降低模型捕捉大气湍流每个波前 Zernike 系数向量空间特征的能力，从而导致预测精度下降。将 WFPM3 与 WFPM 对比可看出，在弱、中与强湍流下，WFPM 的 RMS 分别比 WFPM3 降低了 39.3%、17.8% 与 23.6%。这表明使用特征拼接替换 WFPM 的全局融合模块会降低模型最终融合特征的表达力与判别力，其原因在于差分波前序列的特征较弱，易被噪声淹没，因此 LSTM 提取的湍流动态演化信息包含较多的噪声，直接拼接融合会为最终表示引入噪声。通过交叉注意力机制可从差分波前序列特征中动态筛选与当前波前预测相关的信息，并减少噪声的融入。

表 3 不同湍流下的量化结果

项目强度	模型	均方根 RMS/rad	标准偏差 STD/rad
弱湍流	WFPM1	0.1032	0.0117
	WFPM2	0.0803	0.0098
	WFPM3	0.0829	0.0095
	WFPM	0.0503	0.0058
中湍流	WFPM1	0.1547	0.0175
	WFPM2	0.1232	0.0144
	WFPM3	0.1148	0.0129
	WFPM	0.0944	0.0097
强湍流	WFPM1	0.2389	0.0270
	WFPM2	0.2166	0.0243
	WFPM3	0.1978	0.0224
	WFPM	0.1512	0.0185

4 结 论

为了解决自适应光学中波前传感器与波前校正之间的固有时延问题，提出了基于波前预测模型的自适应光学波前校正方法。所提波前预测模型基于历史波前序列构建差分波前序列，使用 LSTM 提取波前畸变的动态演化特征，从而提高模型对动态大气湍流的自适应能力。使用 Transformer 编码器提取波前序列中各波前帧之间的长程依赖关系，并使用多尺度卷积层增强其对每个波前 Zernike 系数空间特征的能力。利用交叉注意力机制从动态特征中自适应地筛选与当前波前预测最相关的动态特性，并与 Transformer 编码特征进行全局融合。本文方法实现了稳定的波前预测性能，在天文观测、激光通信和显微成像等领域的自适应光学中可发挥积极作用。

尽管所提模型的波前预测误差较低，但模型的训练与调参依然是一项重要且复杂的工作。未来将利用迁移学习技术降低模型的训练成本，使其可快速适用于不同场景下的波前预测任务，进一步提升其实用性。

参考文献：

[1] 刘莹奇,陆红强,舒营恩,等. 机载战术激光武器的低阶自适应光学校正技术研究[J]. 应用光学, 2025, 46(2): 412—418.
Liu Yingqi, Lu Hongqiang, Shu Yingen, et al. Research on correction technology of low order adaptive optics for airborne tactical laser weapons[J]. Journal of Applied Optics, 2025, 46 (2): 412—418.

[2] Pantong Y, Rui L, David M K. Construction and use of an adaptive optics two-photon microscope with direct wavefront sensing[J]. Nature Protocols Erecipes for Researchers, 2023, 18(12): 3732—3766.

[3] Li J, Zhang Z, Gao J, et al. Bandwidth of adaptive optics system in atmospheric coherent laser communication[J]. Optics Communications, 2016, 359(7): 254—260.

[4] 黄盛炀,习锋杰,宁禹,等. 相位光栅型曲率传感器的波前校正算法[J]. 强激光与粒子束, 2011, 23(10): 2573—2577.
Huang Shengyang, Xi Fengjie, Ning Yu, et al. Reconstruction

- algorithm for wavefront curvature sensor with phase grating[J]. High Power Laser and Particle Beams, 2011, 23(10): 2573—2577.
- [5] 卞点, 骆雅婷, 侯登峰, 等. 偏振可调谐式剪切干涉的大畸变波前实时重构[J]. 光学精密工程, 2024, 32(15): 2325—2333. Bian Dian, Luo Yating, Hou Dengfeng, et al. Polarization-tunable shearing interferometry method for real-time reconstruction of large aberration wavefronts[J]. Optics and Precision Engineering, 2024, 32(15): 2325—2333.
- [6] 梁静远, 庞明志, 柯熙政. 无线光通信中大气湍流抑制方法[J]. 电子测量与仪器学报, 2024, 38(11): 1—14. Liang Jingyuan, Pang Mingzhi, Ke Xizheng. Atmospheric turbulence suppression method in optical wireless communication[J]. Journal of Electronic Measurement and Instrument, 2024, 38(11): 1—14.
- [7] Caroline Kulcsár, Raynaud H F, Petit C, et al. Minimum variance prediction and control for adaptive optics[J]. Automatica, 2012, 48(9): 1939—1954.
- [8] Poyneer L A, Jean-Pierre Véran. Kalman filtering to suppress spurious signals in adaptive optics control[J]. Journal of the Optical Society of America A Optics Image Science & Vision, 2010, 27(11): 223—234.
- [9] Gray M, Petit C, Rodionov S, et al. Local ensemble transform Kalman filter, a fast non-stationary control law for adaptive optics on ELTs: theoretical aspects and first simulation results[J]. Optics Express, 2014, 22(17): 894—913.
- [10] Cerqueira P, Pisco P, Verhaegen M. Sparse data-driven wavefront prediction for large-scale adaptive optics[J]. Journal of the Optical Society of America A, Optics, image science, and vision, 2021, 38(7): 992—1002.
- [11] Zhu L, Gao Z, Ge X, et al. Highly stable spatio-temporal prediction network of wavefront sensor slopes in adaptive optics[J]. Sensors, 2023, 23(22): 9260—9260.
- [12] Xu Zhenxing, Yang Ping, Hu Ke, et al. Deep learning control model for adaptive optics systems[J]. Applied Optics, 2019, 58(8): 1998—2009.
- [13] 邱从攀, 刘国栋, 张大勇, 等. 深度学习在波前重构与波前预测中的研究进展[J]. 强激光与粒子束, 2024, 36(7): 071002.1—071002.10. Qiu Congpan, Liu Guodong, Zhang Dayong, et al. Research progress in deep learning for wavefront reconstruction and wavefront prediction[J]. High Power Laser and Particle Beams, 2024, 36(7): 071002.1—071002.10.
- [14] Wang N, Zhu L, Ma S, et al. Deep learning-based prediction algorithm on atmospheric turbulence-induced wavefront for adaptive optics[J]. Photonics Journal, IEEE, 2022, 14(5): 1—10.
- [15] Chen J, Shah V, Liu L. Performance of a U-Net-based neural network for predictive adaptive optics[J]. Optics Letters, 2021, 46(10): 2513—2516.
- [16] Xuewen L, Tim M, Chris S, et al. Wavefront prediction using artificial neural networks for open-loop adaptive optics[J]. Monthly Notices of the Royal Astronomical Society, 2020, 496(1): 456—464.
- [17] Chen Y. LSTM recurrent neural network prediction algorithm based on Zernike modal coefficients[J]. Journal for Light-and-Electronoptic, 2020, 203(9): 163796.1—163796.8.
- [18] Wu J, Tang J, Zhang M, et al. PredictionNet: a long short-term memory-based attention network for atmospheric turbulence prediction in adaptive optics[J]. Applied Optics, 2022, 61(13): 3687—3694.
- [19] 闫丽娟, 梁冰. 大气湍流下激光通信的波前还原研究[J]. 光学技术, 2025, 51(2): 210—217. Yan Lijuan, Liang Bin, Study on wavefront recovery of laser communication over atmospheric turbulence[J]. Optical Technique, 2025, 51(2): 210—217.
- [20] Dai G M. Modal compensation of atmospheric turbulence with the use of Zernike polynomials and Karhunen - Loève functions[J]. Journal of the Optical Society of America A, 1995, 12(10): 2182—2193.
- [21] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS 2017). Long-Beach, USA, IEEE: 2017: 5998—6008.
- [22] 王宁, 朱里程, 葛欣兰, 等. 基于注意力机制的自适应光学开环斜率预测[J]. 中国激光, 2024, 51(6): 0605001.1—0605001.10. Wang Ning, Zhu Licheng, Ge Xinlan, et al. Open-loop slope prediction in adaptive optics based on attention mechanism[J]. Chinese Journal of Lasers, 2024, 51(6): 0605001.1—0605001.10.
- [23] Guyon E, Wesfreid J E, Roux S. Experiments with rayleigh-bénard convection[M]. Dynamics of Spatio-Temporal Cellular Structures. Berlin, Heidelberg:Springer, 2007: 67—94.

(上接 202 页)

- [9] Zhang Z, Panov N, Andreeva V, et al. Optimum chirp for efficient terahertz generation from two-color femtosecond pulses in air[J]. Applied Physics Letters, 2018, 113(24): 241103.
- [10] Gao M, Xu X, Lou J, et al. Enhanced and frequency-selectable terahertz emission from two crossed air-plasmas[J]. Physical Review Research, 2023, 5(2): 023091.
- [11] Wang T, Ju J, Liu Y, et al. Waveform control of enhanced THz radiation from femtosecond laser filament in air[J]. Applied Physics Letters, 2017, 110(22): 221102.
- [12] Simpson T, Pigeon J, Ambat M, et al. Spatiotemporal control of two-color terahertz generation[J]. Physical Review Research, 2024, 6(1): 013041.
- [13] Sheng W, Tang F, Zhang Z, et al. Spectral control of terahertz radiation from inhomogeneous plasma filaments by tailoring two-color laser beams[J]. Optics Express, 2021, 29(6): 8676—8684.
- [14] Zhao J, Chu W, Wang Z, et al. Strong spatial confinement of terahertz wave inside femtosecond laser filament[J]. ACS Photonics, 2016, 3(12): 2338—2343.
- [15] Mou S, Tomarchio L, D'Arco A, et al. Impact of laser chirp on the polarization of terahertz from two-color plasma[J]. Photonics Research, 2023, 11(6): 978—985.
- [16] Koulouklidis A, Gollner C, Shumakova V, et al. Observation of extremely efficient terahertz generation from mid-infrared two-color laser filaments[J]. Nature communications, 2020, 11(1): 292.
- [17] Stathopoulos A, Skupin S, Zhou B, et al. Waveshape of terahertz radiation produced by two-color laser-induced air plasmas[J]. Physical Review Research, 2024, 6(4): 043274.
- [18] 李航, 张颖, 孙文峰, 等. 基于共线型双等离子体的双色场辐射太赫兹波频谱调制[J]. 光学技术, 2019, 45(04): 491—494. Li H, Zhang Y, Sun W, et al. Spectral modulation of terahertz radiation from collinear double-plasma two-color fields[J]. Optical Technology, 2019, 45(04): 491—494.