

引用格式: BI Huicong, LIU Tao, ZHANG Rongxiang, et al. Deep Learning-Based Channel Parameter Estimation for Free-Space Quantum Communication[J]. Acta Photonica Sinica, 2026, 55(7):0727001

毕慧聪,刘涛,张荣香,等. 基于深度学习的自由空间量子通信信道参数估计[J].光子学报,2026,55(7):0727001

基于深度学习的自由空间量子通信信道参数估计

毕慧聪¹,刘涛^{2,3,4},张荣香¹,周允城¹,袁子博¹

(1 河北大学 物理科学与技术学院,保定 071002)

(2 华北电力大学 燕赵电力实验室,保定 071003)

(3 华北电力大学 电子与通信工程系,保定 071003)

(4 华北电力大学 河北省电力物联网技术重点实验室,保定 071003)

摘 要:本文围绕自由空间量子通信中大气信道参数精确估计问题,提出一种 TCN-Transformer-CrossAttention(TTC)融合预测模型,构建面向量子通信应用的能见度与衰减预测框架。该方法充分发挥时间卷积神经网络对局部多尺度时序模式的提取能力与变换器对长程依赖关系建模的优势,通过交叉注意力实现不同特征表征间的对齐与自适应加权融合,从而实现端到端的信道衰减系数多步预测。实验以 2020—2025 年保定地区逐小时气象数据为基础,采用均方根误差、均方误差、平均绝对误差与决定系数作为评价指标,并与多种典型模型进行对比验证。结果表明,所提模型在不同预测步长下均表现出较高拟合度,一步预测决定系数达到 95.68%,均方根误差为 0.0915;在两步与三步预测任务中仍能保持稳定性能;与 BPNN、LSTM、GRU、Transformer、TCN-Transformer 以及 Transformer-CrossAttention 等模型相比,所提方法在误差指标与拟合优度方面均取得最优结果,验证了其在自由空间量子通信信道衰减参数估计与链路状态预测中的应用潜力。

关键词:自由空间量子通信;深度学习;衰减系数预测;注意力机制;Transformer

中图分类号: TN929.12

文献标识码: A

doi: 10.3788/gzxb20265507.0727001

0 引言

20 世纪以来,相对论与量子力学的建立成为现代物理学发展的两大里程碑,并深刻推动了信息技术与通信技术的变革。量子力学的发展催生了量子信息科学这一交叉学科。2022 年诺贝尔物理学奖授予 Alain Aspect、John F. Clauser 和 Anton Zeilinger,以表彰他们在纠缠光子实验及贝尔不等式检验方面的开创性贡献^[1]。量子通信作为量子信息科学的重要分支,因其基于量子力学基本原理所具有的理论无条件安全性,成为国际前沿研究热点^[2-4]。在多种实现方式中,自由空间量子通信凭借损耗小、部署灵活和适于远距离传输等优势,被认为是构建全球量子网络的重要路径^[5-6]。

自 Bennett 与 Brassard 提出 BB84 协议以来^[7],量子密钥分发技术不断取得突破。1989 年实现首次自由空间 QKD 实验^[8],Ekert 提出基于量子纠缠的 E91 协议^[9],随后完成了多种距离条件下的光纤与自由空间实验验证^[10-12]。我国在该领域取得一系列重要进展:2016 年“墨子号”量子卫星成功发射并实现百公里级纠缠

基金项目:河北省高等教育教学改革研究与实践项目(批准号:2025GJJG035)、国家自然科学基金(批准号:62071180)

第一作者:毕慧聪(2001—),女,硕士生,主要研究方向为光通信、量子通信等方面。E-mail:2772785287@qq.com

通讯作者:刘涛(1981—),男,博士,副教授,硕士生导师,主要研究方向为光通信、量子通信和非线性光学等方面。E-mail:taoliu@ncepu.edu.cn;张荣香(1981—),女,博士,教授,硕士生导师,主要研究方向为光通信和视觉检测等方面。E-mail:zrx@hbu.edu.cn

收稿日期:2026-03-02;**录用日期:**2026-04-30

<http://www.photon.ac.cn>

分发^[13],2020年完成1120公里量子纠缠分发^[14],2024年实现了城域多节点量子网络实验^[15]。除传统BB84型方案外,面向高安全性与超远距离传输的QKD协议也取得了重要突破。例如,测量设备无关量子密钥分发(MDI-QKD)实验上已实现442 km超低损耗光纤传输,刷新了典型MDI-QKD的最远传输纪录^[16];双场量子密钥分发(TF-QKD)进一步完成1002 km光纤距离实验演示,展现了突破无中继点对点传输距离限制的巨大潜力^[17]。这些成果表明自由空间量子通信正逐步迈向实用化与网络化阶段。然而,在实验距离不断突破的同时,自由空间信道的复杂大气环境问题正日益凸显。Nie等研究表明,雾霾、雷暴云等气象条件会显著增加信道衰减,降低量子信号的传输效率与系统稳定性^[18-20]。

从物理机制上看,大气衰减系数与能见度密切相关,能见度的变化直接反映了大气气溶胶与水汽浓度的变化,进而影响光子的散射与吸收强度。因此,在自由空间量子通信系统中,能见度不仅是一个气象参数,更是影响信道质量和通信性能的关键变量。如果能够实现对能见度的高精度预测,便可提前评估信道损耗变化趋势,动态优化发射功率、调制参数与链路策略,从而提高量子通信系统的稳定性与可靠性。由此可见,量子通信性能优化与能见度预测之间具有内在的物理与工程关联。与此同时,机器学习在量子通信系统中的应用也逐渐从单一参数建模扩展到协议优化、系统稳定控制与安全监测等多个层面。已有研究表明,机器学习可用于量子密钥分发协议的快速优选与资源配置、相位调制稳定控制、双场QKD中的相位漂移预测,以及实际QKD系统中器件缺陷与攻击行为的自动识别,从而为量子通信系统的智能化运行与实时优化提供了新思路^[21-24]。

在能见度预测研究方面,学者们已开展了大量探索。早期研究主要基于统计与数值模式方法,随后人工神经网络逐步应用于该领域。王恺等构建风险神经网络模型提高预测精度^[25],Boudala等利用气象参数实现机场能见度预测^[26],陈曲等采用NARX模型验证了神经网络在短期预报中的有效性^[27]。之后研究不断引入改进算法,如规则集合方法^[28]、数值模式订正方法^[29]和遗传神经网络模型^[30]。近年深度学习方法逐渐成为主流趋势。Lei Zhu等构建深度学习回归模型^[31],Z Lu等提出层次稀疏表示及TCN迁移学习模型^[32-34],余东昌等基于LightGBM实现能见度预测^[35]。2023—2024年,混合模型与长时序模型进一步发展,如LSTM-GRU与CNN融合模型^[36]、GBRT模型^[37]以及TieGAN-Informer模型^[38]。尽管现有研究在气象预报与航空保障等领域已取得一定进展,但多数工作仍以短临预报或局部区域应用为主,较少面向自由空间量子通信链路优化这一工程需求开展针对性建模;同时,在复杂大气条件下实现长时序、高精度、的信道参数预测方面仍存在提升空间。因此,有必要从量子通信业务场景出发,对深度学习模型结构进行改进,以更有效地表征多源气象变量的非线性耦合关系,并增强对长时间依赖特征的建模能力。

基于此,本文围绕自由空间量子通信中大气信道参数精确估计问题,提出一种TCN-Transformer-CrossAttention(TTC)融合预测模型,构建面向量子通信应用的衰减系数预测框架。该模型以TCN作为前端时序特征提取器,利用其因果卷积与扩张卷积在多尺度上捕获局部到中长程的动态变化;随后引入Transformer对长时间跨度上的全局依赖进行建模,弥补传统卷积结构在超长依赖表达上的不足;在此基础上设计Cross-Attention交叉注意力机制,实现气象多变量特征与目标相关表示之间的精准对齐与动态加权,强化模型对关键环境因素(如湿度、气压、风速、能见度等)在不同天气过程下“贡献度变化”的自适应感知能力。相较于单一结构模型,该方法在工程上具备长时序依赖与多尺度局部模式的协同建模,兼顾突变过程与缓变趋势的突出优势,拥有跨特征交互增强,有效提升多源气象数据非线性耦合关系的表达能力以及并行高效与训练稳定性更强,更适合大规模历史数据训练。本研究旨在实现面向量子通信系统的高精度衰减系数预测与估计,为提高自由空间量子通信链路的稳定性和可靠性提供理论支撑与技术保障,并为量子通信网络的工程化和规模化发展提供参考。

1 数据处理与分析

本实验所使用的数据集为保定地区气象数据,气象站区站编号54602,位置为北纬38.73°,东经115.48°。数据集记录了2020年6月至2025年2月的气象数据,包含气压、温度、相对湿度、风速、能见度数据,数据采样间隔为1 h,数据样例如表1所示,衰减系数由能见度通过公式(2)、(3)转化得到,其中通信波长取值为850 nm,气温、气压、湿度、风速数据均为平均值。

表 1 数据样例
Table 1 Sample of the Dataset

Time	Temoerture /°C	Airpressure /%	Humidity /%	Wind veloci- ty /(m·s ⁻¹)	Visibility /km	Attenuation coef- ficient/km ⁻¹
2018-3-3 0:00	3.9	1019.7	93	1.6	10.476	0.2119
2018-3-3 1:00	3.9	1020.3	90	1.3	10.722	0.2070
2018-3-3 2:00	3.1	1020.7	97	1.8	9.003	0.2466
2018-3-3 3:00	0.5	1020.9	100	2.4	5.08	0.4659
2018-3-3 4:00	-1.4	1020.6	100	0.7	2.252	1.2799
2018-3-3 5:00	-0.1	1020.8	88	2.9	16.992	0.1306

1.1 大气衰减系数与能见度的关系

量子光信号在大气信道传播过程中,会受到多种物理机制的共同作用,包括大气分子吸收、气溶胶颗粒吸收以及瑞利散射和米氏散射等效应^[39],从而引起信号能量的衰减。通常将信号通过大气前后的强度之比定义为大气信道传输效率 η_{atm} ,其与大气条件及传播距离之间的关系可表示为

$$\eta_{atm} = \exp(-\alpha L) \quad (1)$$

其中, α 表示表征大气衰减强度的系数, L 为传播距离。参数 α 可通过实测数据获取。为便于工程计算,文献^[40]在实验结果基础上进行了曲线拟合,给出了衰减系数与能见度之间的经验表达式

$$\alpha(\lambda) = \frac{3.91}{V_v} \left(\frac{0.55}{\gamma} \right)^q \quad (2)$$

式中, γ 为所采用的信号波长, V_v 表示能见度。指数 q 的取值随能见度区间变化,其对应关系为

$$q = \begin{cases} 1.3, & 6\text{km} < V_v \\ 0.16 V_v + 0.34, & 1\text{km} < V_v < 6\text{km} \\ V_v - 0.5, & 0.5\text{km} < V_v < 1\text{km} \\ 0, & V_v < 0.5\text{km} \end{cases} \quad (3)$$

本文依据式(2)与式(3)将能见度观测值转换为对应的衰减系数数据,并将其作为输入向量中的关键参数之一。

设某时刻的大气衰减系数为 α_t ,气象因子向量为

$$\mathbf{x}_t = [r_t, h_t, T_t, p_t, v_t, \dots]^\top \quad (4)$$

其中 $\mathbf{x}_t$ 表示时刻 t 的气象因子向量, r_t 表示降雨量, h_t 表示湿度, T_t 表示温度, p_t 表示气压, v_t 表示能见度等,则衰减系数可表示为

$$\alpha_t = f(\mathbf{x}_t) \quad (5)$$

由于衰减形成过程涉及吸收、散射及传播环境扰动等多重物理机制,函数 $f(\cdot)$ 通常并非线性形式。对其在某一工作点附近进行二阶泰勒展开可得:

$$\alpha_t \approx f(\mathbf{x}_0) + \sum_i \frac{\partial f}{\partial x_i} (x_i - x_{0i}) + \frac{1}{2} \sum_i \frac{\partial^2 f}{\partial x_i^2} (x_i - x_{0i})^2 + \sum_{i \neq j} \frac{\partial^2 f}{\partial x_i \partial x_j} (x_i - x_{0i})(x_j - x_{0j}) \quad (6)$$

其中,一阶项反映单一气象因子的线性影响,二阶项和交叉项分别反映单因子非线性效应及多因子耦合作用。这表明气象因子与衰减系数之间存在显著的非线性耦合关系。进一步考虑时间相关性,衰减预测可写为过去一段时间气象状态的动态映射:

$$\alpha_t = F(\mathbf{x}_{t-L+1}, \dots, \mathbf{x}_t) \quad (7)$$

其变化过程同时包含局部短时波动项与全局长期演化项。因此,本文采用TCN提取局部时序特征,利用Transformer建模长程依赖关系,并通过Cross-Attention实现局部与全局特征的自适应交互与融合,从而更有针对性地表征衰减演化中的复杂非线性耦合机制。

1.2 数据归一化处理

不同气象数据在量纲和取值范围上往往存在较大差异。若将其直接输入模型,数值范围较大的特征容

易在训练过程中占据主导地位,进而对模型收敛速度和最终预测精度造成影响。因此,在建模之前,有必要先对数据进行统一尺度处理。

归一化处理的主要作用,在于通过比例变换减弱不同特征之间的量纲差别,使各变量被映射到相近的数值区间内。这样一来,模型训练过程会更加稳定,对特征的学习也会更均衡。考虑到气象数据具有较明显的时间序列特征,如果对原始分布结构改动过大,时序规律的表达可能会受到削弱,模型对变化趋势的学习能力也可能因此下降。

基于上述考虑,本文采用 Min-Max 方法对数据进行了归一化处理。在完成尺度统一的同时,该方法对原始分布特征保留得相对较好,更适合本研究中的时序建模任务。

$$x = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (8)$$

其中, X 为原始数据, $X_{\min}$ 与 $X_{\max}$ 分别为样本最小值和最大值。该方法将数据线性映射至 $[0, 1]$ 区间。

1.3 相关性分析

能见度受多种气象因子共同影响。若输入特征过多,不仅会增加模型参数规模、降低计算效率,还可能引入冗余信息从而影响模型泛化能力。因此,本实验对数据集中候选气象因子与能见度之间的线性相关性进行筛选,采用皮尔逊相关系数。

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (9)$$

r 为衡量变量体现 x 与 y 的线性相关程度,其取值范围为 $[-1, 1]$, $|r|$ 越大表示线性相关性越强。基于计算结果绘制相关性热力图如图 1 所示。

由图 1 可知,能见度与相对湿度(Rel Hum)呈较明显负相关($r=-0.50$),表明湿度增大时能见度总体上有所下降趋势;与气压(Sth Press)呈正相关($r=0.29$),与风速(Wind Spd)也呈弱正相关($r=0.21$),说明气压升高及风速增大与能见度提高在统计意义上具有一定一致性;温度(Temp)与能见度呈弱负相关($r=-0.20$)。总体而言,所选变量与能见度的相关系数绝对值均在 0.20 及以上,具备作为模型输入特征的相关性基础。




图 1 相关系数热力矩阵图

Fig.1 Pearson Correlation Coefficient Heatmap

1.4 评价指标

(1) 均方根误差(RMSE)

RMSE 用于衡量预测值与真实值之间的整体偏差程度,能够反映模型预测的准确性。RMSE 越小,表

明预测误差越小、模型预测性能越好。

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (10)$$

式中, n 为样本数量; y_i 为真实值; $\hat{y}_i$ 为预测值;

(2) 平均绝对误差(MAE)

MAE表示预测值与真实值之间误差绝对值的平均水平,能够直观反映模型的平均预测偏差。MAE越小,表明模型预测精度越高。

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (11)$$

(3) 均方误差(MSE)

MSE刻画预测误差平方的平均值,对较大误差更敏感,可用于衡量模型预测误差的整体水平。MSE越小,表明模型预测效果越好。

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (12)$$

(4) 决定系数(R^2)

R^2 是评价模型拟合优度的常用指标,用于衡量模型对观测数据方差的解释能力,其取值越接近1,表明模型拟合效果越好、对未知样本的预测能力越强。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (13)$$

式中 $\bar{y}$ 为真实值的平均值。综合采用RMSE、MAE、MSE和 R^2 指标可从误差幅度、误差敏感性及拟合优度等方面对模型的有效性、准确性与稳健性进行较为全面的评价。

2 仿真模型设计

为提升大气衰减系数预测中对复杂非线性波动及多尺度时序依赖的表征能力,本文构建了TCN-Transformer-Cross-Attention(TTC)联合预测架构。由于大气衰减序列具有显著的非线性、非平稳性以及多时间尺度耦合特征,其变化过程既包含短时间范围内的局部扰动与突变信息,也受到较长时间尺度下气象条件持续演化的影响,单一模型往往难以同时兼顾局部细节刻画与全局趋势建模。基于此,本文将TCN、Transformer与Cross-Attention结合,以增强模型对复杂衰减变化过程的表征能力并提升预测精度与稳定性。TTC的整体结构如图2所示:原始时间序列输入后并行进入TCN分支和Transformer分支,分别提取局部时序特征与全局时序特征,随后在Cross-Attention模块中完成跨分支信息交互与融合,最终输出预测结果。

其中,TCN分支以一维卷积为核心,通过膨胀卷积和多层卷积模块逐步扩大感受野,实现对输入序列局部波动模式和多尺度动态信息的提取。该分支更侧重建模相邻时间步之间的短期相关性与局部变化规律,因此其输出定义为局部时序特征。选择TCN的原因在于,大气衰减系数常受降雨、湿度变化及局部传播环境扰动等因素影响,表现出明显的短时波动和局部突变特征,而TCN在局部模式提取、并行计算和训练稳定性方面具有优势,适合用于刻画这类短期动态信息。

Transformer分支由输入嵌入层和编码器模块构成,编码器内部包含多头自注意力机制和前馈神经网络,并结合残差连接与层归一化操作,以增强训练稳定性。该分支主要用于捕获序列中跨时间步的长程依赖关系与整体演化趋势,其输出定义为全局时序特征。这是因为衰减变化不仅与当前邻近时刻的信息有关,还往往受到较长时间范围内气象状态累积效应和环境演化趋势的影响,因此引入Transformer有助于提升模型对全局动态变化的建模能力。

在特征融合阶段,本文引入Cross-Attention机制实现局部时序特征与全局时序特征之间的深度交互。

设 TCN 分支输出为 $X_t \in \mathbb{R}^{L \times d_t}$, Transformer 分支输出为 $X_g \in \mathbb{R}^{L \times d_g}$, 其中 L 表示序列长度, d_t 和 d_g 分别表示两分支的特征维度。为实现跨分支对齐, 首先通过线性映射将两类特征投影到统一隐空间维度 d , 构造查询矩阵、键矩阵和值矩阵:

$$Q = X_t W_Q, \quad K = X_g W_K, \quad V = X_g W_V \quad (14)$$

其中, Q 来源于 TCN 分支的局部时序特征, K 和 V 来源于 Transformer 分支的全局时序特征。随后, 通过式(15)

$$A = \text{Softmax}\left(\frac{QK^\top}{\sqrt{d}}\right) \quad (15)$$

计算注意力权重, 并对 V 进行加权汇聚, 得到融合特征 F

$$F = A V \quad (16)$$

该过程使模型能够以局部特征为引导, 从全局特征中自适应选择与当前预测最相关的信息, 从而在局部波动模式与长期演化趋势之间建立有效联系。相比简单拼接或加权求和, Cross-Attention 能够实现更粒度的特征筛选与动态融合, 增强两类特征之间的互补性。

最终, 融合特征 F 经过全连接预测层映射为目标变量的回归输出, 完成大气衰减系数预测。总体而言, TTC 架构通过“TCN 局部时序建模—Transformer 全局依赖建模—Cross-Attention 自适应融合”的协同设计, 同时兼顾了短期波动细节与长期演化趋势, 能够更好地适应大气衰减系数这类复杂非平稳时间序列预测任务的建模需求。




图2 TTC 网络结构图

Fig.2 Structural Diagram of the TTC Network

2.1 实验内容及参数设置

本文采用 2020–2025 年保定市逐小时气象数据为试验数据, 对本实验模型的衰减系数预测效果进行验证。将经数据预处理与相关性分析筛选后的气象要素作为模型输入样本, 其中输入特征为气压、温度、相对湿度、风速、能见度, 输出特征为大气衰减系数, 并按照 6:2:2 的比例将数据集划分为训练集、验证集和测试集。随后, 采用滑动时间窗口方法对输入样本进行重构, 并将处理后的数据输入模型的输入层。模型的滑动时间窗口设定为 12 h, 并分别设置 1 步、2 步与 3 步作为预测步长(时序预测长度), 其余超参数的具体取值如表 2 所示。以 RMSE、MSE、MAE 和 R^2 为评价指标, 对 TTC 模型预测效果进行评价。将能见度预测试验分为 3 组, 第一组分别对未来 1–3 步的衰减系数进行预测试验, 以验证 TTC 模型的有效性; 第二组通过将本文 TTC 模型与 BPNN、LSTM、GRU、Transformer、TCN–Transformer、Transformer–CrossAttention 等模型的预测效果进行对比, 以验证 TTC 模型预测的准确性; 第三组对济南地区进行跨区域泛化能力验证, 以适配自由空间量子通信的多场景部署需求。

为验证时间窗口划分对模型预测性能的影响, 在统一模型结构与训练参数条件下, 本文设置了 12 h、24

表2 硬件平台配置和模型参数
Table 2 Hardware platform configuration and model parameters

配置	型号	参数设置	数值
操作系统	Windows11	优化器	Adam
CPU	Intel40 核 E5 2670 处理器	迭代次数	100
GPU	NVIDIA RTX3090	批次值	256
内存	64G	学习率	0.0003
CDUA	11	隐藏层	128
编程语言	Python3.12	Dropout 率	0.3

h、48 h 及 72 h 等不同历史时间窗口进行单步预测对比实验。对应预测结果如图 3 所示,评价指标统计结果见表 3。结果表明,时间窗口长度对模型预测性能具有显著影响,其中 12 h 窗口在 RMSE、MSE、MAE 及 R^2 指标上均表现最优,说明该窗口长度能够更有效地刻画气象要素的短期动态变化特征,因此确定其为本研究采用的时间窗口设置。




图3 不同时间窗口(a)12 h(b)24 h(c)48 h(c)72 h的预测结果对比
Fig.3 Comparison of prediction results under different time windows: (a) 12 h, (b) 24 h, (c) 48 h, (d) 72 h

表3 不同时间窗口评价指标值
Table 3 Comparison of evaluation metrics under different time windows

时间窗口/h	R_{MSE}/km^{-1}	M_{SE}/km^{-1}	M_{AE}/km^{-1}	R^2
12	0.0915	0.00837	0.0734	95.68%
24	0.1645	0.02706	0.1021	92.13%
48	0.1982	0.03928	0.1328	90.37%
72	0.2638	0.06959	0.1579	88.65%

2.2 模型验证

图4从拟合曲线对比角度对模型多步预测性能进行了直观展示。三种预测步长下的预测曲线与真实曲线在整体走势上保持较高一致性,能够较好反映未来系数序列随时间变化的主要形态特征;同时,对于序列

中的关键波动段,预测曲线与真实曲线在峰值出现的时间位置上具有较好的对应关系,说明模型对时序依赖结构与变化节律具有有效的学习与表达能力。在1步预测(图4(a))中,预测结果对真实曲线的跟随性最强,能够精细刻画局部变化并保持较高贴合度;在2步与3步预测(图4(b)、(c))中,预测曲线仍能稳定复现序列的主要变化过程与显著波动特征,体现出模型在不同预测视距下对趋势信息与关键波动结构的持续捕捉能力。

表4进一步从定量评价角度给出了不同预测步长下模型的RMSE、MSE、MAE以及 R^2 。从结果可以看出,在不同预测步长下模型均保持了较高的拟合水平,且评价指标呈现出随步长变化的合理规律:1步预测时RMSE为0.0915、MSE为0.00837、MAE为0.0734, R^2 达到95.68%,表明模型对序列的短期动态具有很强的刻画能力;当步长扩展至2步时,RMSE为0.2436、MSE为0.05934、MAE为0.1458, R^2 仍保持在89.36%的较高水平,说明模型在更长预测视距下依旧能够有效跟踪序列变化并维持良好的解释能力;在3步预测情况下,RMSE为0.4315、MSE为0.18619、MAE为0.2923, R^2 仍达到83.41%,显示模型在更远期预测中依然能够较好地表征序列整体变化特征与主要信息成分。总体而言,随着预测步长增加,误差指标变化与 R^2 的变化趋势符合多步预测任务中信息逐步外推的统计特征,而各步长下 R^2 均处于较高区间,体现出模型对未来系数序列的稳定拟合能力与较强的泛化表现。

综合图4与表4可知,该模型在多步预测设置下均表现出良好的趋势一致性与较高的拟合优度,能够为未来系数序列的短期与中期预测提供可靠支撑。




图4 对未来衰减系数预测1步(a)2步(b)3步(c)的真实值和预测值的曲线拟合
Fig.4 Fitting Curves of Actual and Predicted Values for 1-Step (a), 2-Step (b), and 3-Step (c) Forecasts of the Future Attenuation Coefficient

表4 TTC不同步长评价指标值
Table 4 Performance Metrics of TTC at Different Prediction Horizons

预测步长	R_{MSE}/km^{-1}	M_{SE}/km^{-1}	M_{AE}/km^{-1}	R^2
1步	0.0915	0.00837	0.0734	95.68%
2步	0.2436	0.05934	0.1458	89.36%
3步	0.4315	0.18619	0.2923	83.41%

为进一步验证 TTC 模型预测的准确性,本实验选取 BPNN、LSTM、GRU、Transformer、TCN-Transformer、Transformer-CrossAttention 等典模型作为对比对象,并在统一数据集与评价体系下对各模型进行参数调优,使其预测性能达到相对最优水平,随后将各模型的预测结果与 TTC 模型进行对比分析,结果如图 5 与表 5 所示。由图 5 可见,不同模型在 RMSE、MAE 与 MSE 三类误差指标上呈现出一致的对比结论:TTC 对应的三项误差柱形均处于最低水平,说明 TTC 在整体预测偏差控制与误差波动抑制方面表现更优;同时,随着模型结构从传统前馈网络与循环网络逐步向更强的时序表征结构发展,误差指标整体呈下降趋势。

为量化不同模型的预测性能差异,表 5 给出了各模型的 RMSE、MSE、MAE 与 R^2 指标。结果表明,TTC 模型在四项指标上均取得最优表现:其 RMSE 为 0.0915、MSE 为 0.00837、MAE 为 0.0734, R^2 达到 95.68%。与 BPNN、LSTM、GRU、Transformer、TCN-Transformer、Transformer-CrossAttention 相比,TTC 的 RMSE 分别降低约 76.2%、73.3%、67.8%、57.2%、51.27% 和 32.62%,MAE 分别降低约 69.0%、64.8%、55.3%、50.6%、40.66% 和 18.53%,MSE 分别降低约 94.3%、92.9%、89.6%、81.7%、76.21% 和 54.61%,同时 R^2 相较上述模型提升约 2.36~13.30 个百分点。综合图 5 的直观对比与表 5 的定量结果可知,TTC 模型能够更充分地刻画序列中的关键时序信息与变化规律,从而在误差水平与拟合优度方面均表现出更高的预测准确性,为后续应用与分析提供了更可靠的模型支撑。

已有相关研究^[25-32]表明,不同预测模型和方法在不同场景下均取得了一定效果,但由于预测对象、时间尺度及评价指标不同,相关结果难以在统一标准下开展直接对比。文献[29, 30]采用了与本文一致的 R^2 评价指标,且均提供了未来 1 h 的预测结果,因此选取其作为对比对象。对比结果显示,文献[29, 30]的 R^2 分别为 0.92 和 0.8254;相较而言,本文所建模型具有更高的决定系数,预测值与真实值之间线性相关性更强,预测效果更好。




图 5 多种模型评价指标对比柱状图
Fig.5 Comparison of multiple model evaluation metrics

为验证模型的跨区域泛化能力,第三组实验进一步选取济南地区数据开展异地测试,实验结果如图 6 和表 6 所示。可以看出,TTC 模型在济南地区仍能够较好跟踪衰减序列的变化趋势,且在不同预测步长下均保持较为稳定的预测效果。这说明所构建模型对区域变化具有一定适应性,具备跨地区推广应用的潜力。

3 结论

本文利用气象观测实现自由空间量子通信信道衰减系数的高精度多步预测,为链路可用性评估与参数

表 5 多种模型评价指标对比
Table 5 Comparative Analysis of Performance Metrics for Multiple Models

模型	R_{MSE}/km^{-1}	M_{SE}/km^{-1}	M_{AE}/km^{-1}	R^2
BPNN	0.3848	0.14807	0.2367	82.38%
LSTM	0.3429	0.11758	0.2085	87.85%
GRU	0.2843	0.08082	0.1641	89.62%
Transformer	0.2138	0.04571	0.1487	91.81%
TCN—Transformer	0.1876	0.03519	0.1237	92.77%
Transformer—CrossAttention	0.1358	0.01844	0.0901	93.47%
TTC	0.0915	0.00837	0.0734	95.68%




图 6 济南地区对未来衰减系数预测 1 步(a)2 步(b)3 步(c)的真实值和预测值的曲线拟合

Fig.6 Fitting Curves of Actual and Predicted Values for 1-Step (a), 2-Step (b), and 3-Step (c) Forecasts of the Future Attenuation Coefficient in Jinan

表 6 济南地区不同步长评价指标值
Table 6 Evaluation Metrics for Different Forecast Steps in Jinan

预测步长	R_{MSE}/km^{-1}	M_{SE}/km^{-1}	M_{AE}/km^{-1}	R^2
1 步	0.0878	0.00771	0.0651	96.14%
2 步	0.2514	0.06320	0.1572	88.73%
3 步	0.4489	0.20151	0.3019	82.81%

自适应提供依据。结果表明,所构建的 TCN—Transformer—CrossAttention 融合模型在不同预测视距下均具有稳定表现:一步预测拟合优度最高($R^2=95.68\%$, $RMSE=0.0915$),两步与三步预测仍保持较高解释度($R^2=89.36\%$ 与 83.41%),且真实值与预测值曲线在整体趋势与主要波动段一致,说明局部多尺度提取与长程依赖建模在交叉注意力融合下形成有效互补,从而验证了“局部—全局联合建模可提升信道参数预测精度”的研究假设。对比实验进一步给出证据:相较 BPNN、LSTM、GRU、Transformer、TCN—Transformer、Transformer—CrossAttention 等模型,TTC 模型在 RMSE、MSE、MAE 上均取得最小值且 R^2 最高,表明该融合结构在复杂气象耦合驱动的衰减序列建模中具有更优综合性能。最后对济南地区进行跨区域泛化能力

验证,在不同预测步长下均保持较为优秀的预测效果,能够适配自由空间量子通信的多场景部署需求。多方面表明 TTC 模型能够更充分刻画气象因子与信道衰减的非线性关系,可为链路状态预测与工程决策提供可靠支撑。不足在于数据来源较集中、特征维度仍有限;后续将扩展多区域数据,引入气溶胶、污染等变量,并探索在线更新与链路控制闭环应用。

参考文献

- [1] WANG Xiangbin, PAN Jianwei. The Nobel Prize in Physics 2022: Quantum Entanglement[J]. Bulletin of National Natural Science Foundation of China, 2022, 36(6): 928-930.
王向斌,潘建伟.2022年诺贝尔物理学奖:量子纠缠[J].中国科学基金,2022,36(06):928-930.
- [2] Gisin N, Ribordy G, Tittel W, et al. Quantum cryptography [J]. Reviews of Modern Physics, 2002, 74(1): 145-195.
- [3] Guo Guangcan. Research status and future of quantum information technology[J]. Scientia Sinica (Informationis), 2020, 50(9): 1395-1406.
郭光灿.量子信息技术研究现状与未来[J].中国科学:信息科学, 2020, 50(9): 1395-1406.
- [4] Lopez-Leyva J A, Talamantes-Alvarez A, Ponce-Camacho M A, et al. Free-Space-Optical Quantum Key Distribution Systems: Challenges and Trends [M]. Quantum Cryptography in Advanced Networks, 2019.
- [5] Pan Jianwei. Progress of the quantum experiment science satellite (QUESS) Micius Project[J]. Chinese Journal of Space Science, 2020, 40(5): 643-647.
- [6] Cao Yuan, Li Yuhuai, Yang Kuixing, et al. Long-distance free-space measurement-device-independent quantum key distribution[J]. Physical Review Letters, 2020, 125(26): 260503.
- [7] BENNETT C H, BRASSARD G. Quantum cryptography: Public key distribution and coin tossing[J]. Theoretical Computer Science, 2014, 560(1): 7-11.
- [8] BENNETT C H. Quantum cryptography using any two nonorthogonal states[J]. Physical Review Letters, 1992, 68: 3121-3124.
- [9] ARTUR E K. Quantum cryptography based on Bell's theorem[J]. Physical Review Letters, 1991, 67(6): 661.
- [10] MULLER A, ZBINDEN H, GISIN N. Quantum cryptography over 23km in installed under-lake telecom fibre[J]. EPL (Europhysics Letters), 1996, 33: 335-339.
- [11] KURTSIEFER C, ZARDA P, Halder M, et al. A step towards global key distribution [J]. Nature, 2002, 419(6906): 450.
- [12] URSIN R, TIEFENBACHER F, SCHMITT MANDERBACH T, et al. Entanglement-based quantum communication over 144 km[J]. Nature Physics, 2007, 3(7): 481-486.
- [13] YIN Juan, CAO Yuan, LI Yuhuai, et al. Satellite-based entanglement distribution over 1200 kilometers[J]. Science, 2017, 356(6343): 1140-1144.
- [14] YIN Juan, LI Yuhuai, LIAO Shengkai, et al. Entanglement-based secure quantum cryptography over 1120 kilometres [J]. Nature, 2020, 582(7813): 501-505
- [15] Liu Jianlong, Luo Xiyu, Yu Yong, et al. Creation of memory-memory entanglement in a metropolitan quantum network [J]. Nature, 2024, 629: 579-58
- [16] Liu Jingyang, Ma Xiao, Ding Huajian, et al. Experimental demonstration of five-intensity measurement-device-independent quantum key distribution over 442 km[J]. Physical Review A, 2023, 108(2): 022605.
- [17] Liu Yang, Zhang Weijun, Jiang Cong, et al. Experimental twin-field quantum key distribution over 1000 km fiber distance [J]. Physical Review Letters, 2023, 130(21): 210801.
- [18] HAN Liqiang, YOU Yahui. Performance of multiple-input multiple-output free space optical communication under atmospheric attenuation and turbulence effects[J]. Chinese Journal of Lasers, 2016, 43(7): 0706004.
韩立强,游雅晖.大气衰减和大气湍流效应下多输入多输出自由空间光通信的性能[J].中国激光, 2016, 43(7): 0706004.
- [19] LIU Tao, ZHU Cong, SUN Chunyang, et al. Influence of Different Weather Conditions on Performance of Free-Space Quantum Communication System[J]. Acta Optica Sinica, 2020, 40(2): 0227001.
刘涛,朱聪,孙春阳,等.不同天气条件对自由空间量子通信系统性能的影响[J].光学学报, 2020, 40(2): 0227001.
- [20] NIE Min, CHEN Wei, ZHANG Meiling, et al. Influence of Haze on Free-Space Quantum State Transmission[J]. Journal of Xi'an University of Posts and Telecommunications, 2015, 20(1): 19-23.
聂敏,陈伟,张美玲,等.雾霾对自由空间量子态传输的影响[J].西安邮电大学学报, 2015, 20(1): 19-23..
- [21] Xu Jiaxin, Ma Xiao, Liu Jingyang, et al. Automatically identifying imperfections and attacks in practical quantum key distribution systems via machine learning[J]. Science China Information Sciences, 2024, 67(10): 202501.
- [22] Liu Jingyang, Jiang Qinging, Ding Huajian, et al. Highly efficient twin-field quantum key distribution with neural networks [J]. Science China. Information Sciences, 2023, 66(8): 189402.
- [23] Ren Ziang, Chen Yipeng, Liu Jingyang, et al. Implementation of machine learning in quantum key distributions[J]. IEEE

- Communications Letters, 2020, 25(3): 940-944.
- [24] Liu Jingyang, Ding Huajian, Zhang Chunmei, et al. Practical phase-modulation stabilization in quantum key distribution via machine learning[J]. Physical Review Applied, 2019, 12(1): 014059.
- [25] WANG Kai, ZHAO Hong, LIU Aixia, et al. Atmospheric visibility prediction based on risk neural network[J]. China Environmental Science, 2009, (10): 1029-1033.
王恺, 赵宏, 刘爱霞, 等. 基于风险神经网络的大气能见度预测[J]. 中国环境科学, 2009, (10): 1029-1033.
- [26] Boudala F S, Isaac G A, Crawford R W, et al. Parameterization of Runway Visual Range as a Function of Visibility: Implications for Numerical Weather Prediction Models[J]. Journal of Atmospheric & Oceanic Technology, 2011, 29(2): 177-191.
- [27] CHEN Qu, XIA Bin, WANG Song. Visibility prediction based on NARX neural network[C]. The 8th Yangtze River Delta Science and Technology Forum—Meteorological Science and Technology Development Forum.
陈曲, 夏斌, 王淞. 基于NARX神经网络的能见度预测[C]. 第八届长三角科技论坛——气象科技发展论坛.
- [28] Zhou Binbin, Du Jun, Gultepe I, et al. Forecast of Low Visibility and Fog from NCEP: Current Status and Efforts[J]. Pure & Applied Geophysics, 2012, 169(5-6): 895-909.
- [29] GUAN Qin, LI Qingping, HUANG Lingguang, et al. Visibility forecast of fog day in Taiyuan[J]. Journal of Meteorology and Environment, 2013, 29(4): 47-53.
管琴, 李青平, 黄铃光, 等. 太原雾天能见度预报[J]. 气象与环境学报, 2013, 29(4): 47-53.
- [30] MA Chuyan, ZU Jian, FU Qingpan, et al. Prediction of atmospheric visibility based on genetic neural network model[J]. Chinese Journal of Environmental Engineering, 2015, 9(4): 1905-1910.
马楚焱, 祖建, 付清盼, 等. 基于遗传神经网络模型的空气能见度预测[J]. 环境工程学报, 2015, 9(004): 1905-1910.
- [31] Zhu Lei, Zhu Guodong, Han Lei, et al. The application of deep learning in airport visibility forecast[J]. Atmospheric and Climate Sciences, 2017, 7(03): 314.
- [32] Lu Zhenyu, Lu Bingjian, Zhang Hengde, et al. A method of visibility forecast based on hierarchical sparse representation [J]. Journal of Visual Communication & Image Representation, 2019, 58: 160-165.
- [33] ZHANG Jie, XIONG Quan. Visibility forecast of expressway based on BP artificial neural network[J]. Science and Technology & Innovation, 2019, 18: 76-77.
张杰, 熊权. 基于BP人工神经网络的高速公路能见度预报[J]. 科技与创新, 2019, 000(018): 76-77.
- [34] Lu Zhenyu, Zheng Cheng, Yang Tingya. Application of offshore visibility forecast based on temporal convolutional network and transfer learning[J]. Computational Intelligence and Neuroscience, 2020, 2020(1): 8882279.
- [35] YU Dongchang, ZHAO Wenfang, NIE Kai, et al. Visibility forecast model based on LightGBM algorithm[J]. Journal of Computer Applications, 2021, 41(4): 1035-1041.
余东昌, 赵文芳, 聂凯, 等. 基于LightGBM算法的能见度预测模型[J]. 计算机应用, 2021, 41(4): 1035-1041.
- [36] Peláez-Rodríguez C., Pérez-Aracil J., de Lopez-Diz A., et al. Deep learning ensembles for accurate fog-related low-visibility events forecasting [J]. Neurocomputing, 2023, 549: 126435.
- [37] ZHENG Chen, WANG Xuan, WANG Lijie, et al. Atmospheric extinction characteristics and visibility prediction model of typical haze processes at airport[J]. Environmental Engineering, 2024, 42(3): 215-224.
郑宸, 王璇, 王立婕, 等. 机场典型霾过程大气消光特性及能见度预测模型[J]. 环境工程, 2024, 42(03): 215-224.
- [38] MA Yuzhao, ZHANG Yuhang, WANG Lingfei. Long-term airport visibility prediction based on TieGAN-Informer[J]. Journal of Safety and Environment, 2024, 19(3): 1-14.
马愈昭, 张宇航, 王凌飞. TieGAN-Informer 长时机场能见度预测[J]. 安全与环境学报, 2024, 19(03): 1-14.
- [39] HAN Liqiang, WANG Qi, XINTAI Kegui. Performance of free space optical communication in Gamma-gamma atmospheric turbulence[J]. Infrared and Laser Engineering, 2011, 40(7): 1318-1322.
韩立强, 王祁, 信太克归. Gamma-gamma 大气湍流下自由空间光通信的性能[J]. 红外与激光工程, 2011, 40(7): 1318-1322.
- [40] Kim I I, McArthur B, Korevaar E J. Comparison of laser beam propagation at 785 nm and 1550 nm in fog and haze for optical wireless communications [C]. Proceedings of SPIE, 2001, 4214: 26-37.

Deep Learning-Based Channel Parameter Estimation for Free-Space Quantum Communication

BI Huicong¹, LIU Tao^{2,3,4}, ZHANG Rongxiang¹, ZHOU Yuncheng¹, YUAN Zibo¹
(1 College of Physics Science and Technology, Hebei University, Baoding 071002, China)

(2 *Yanzhao Electric Power Laboratory of North China Electric Power University, Baoding 071003, China*)

(3 *Department of Electronic and Communication Engineering, North China Electric Power University, Baoding 071003, China*)

(4 *Hebei Key Laboratory of Power Internet of Things Technology, North China Electric Power University, Baoding 071003, China*)

Abstract: Atmospheric channel parameter estimation is a key issue in free space quantum communication systems. Since transmission performance and link stability are very sensitive to changes in meteorological conditions. Among these factors, visibility and channel attenuation are particularly important, because they directly affect the transmission loss of photons, thus affecting the reliability of quantum links. Aiming at the problem of short-term accurate prediction of atmospheric attenuation parameters, this paper proposes a TCN-Transformer-Cross Attention (TTC) fusion model, and establishes a visibility and attenuation coefficient prediction framework for free space quantum communication applications. By combining the ability of Temporal Convolutional Networks (TCN) to extract local multi-scale temporal patterns and the advantages of Transformer architecture in modeling long-distance dependencies, and further introducing cross-attention mechanism, this method realizes end-to-end multi-step prediction of channel attenuation coefficient. Based on the hourly meteorological observation data of Baoding City from 2020 to 2025, the effectiveness of the proposed model is systematically evaluated through multiple prediction tasks and comparative experiments with several representative benchmark models. The attenuation coefficient of the free space quantum communication channel is closely related to the time evolution of atmospheric conditions, especially the meteorological variables related to visibility. Therefore, accurate prediction depends not only on capturing local fluctuations and short-term change patterns, but also on modeling the long-term correlation and feature correlation interactions in the observation sequence. In this work, we first use the hourly meteorological data of Baoding area from 2020 to 2025 to construct a multivariate time series dataset, and model the prediction of channel attenuation coefficient as a supervised sequence learning problem. On this basis, one-step, two-step and three-step prediction tasks are designed to evaluate the short-term prediction ability of the model in different horizons. From the perspective of modeling, the proposed TTC framework can be understood as a hierarchical fusion architecture with complementary timing representation mechanism. The TCN branch is responsible for extracting local and multi-scale temporal features from the input sequence. Through causal convolution and dilated convolution, the receptive field can be effectively expanded while preserving the temporal order of observations, so that the model can capture short-term fluctuations, abrupt local changes and potential periodic structures in atmospheric data. At the same time, Transformer branch is used to learn global context dependence and long-range temporal interaction through self-attention mechanism. Compared with the simple convolution or circular structure, this branch is more suitable for describing the long-range correlation between meteorological observations distributed at different time intervals. In order to further utilize the complementarity between the two branches, a cross-attention module is introduced for feature alignment and adaptive fusion. The Cross-Attention mechanism is not a simple series of local features and global features, but dynamically adjusts the contribution of different representations and enhances the interaction between different time feature spaces, thereby improving the model's ability to focus on the most informative components for attenuation prediction. In this way, the proposed TTC framework establishes an end-to-end mapping from meteorological time series input to future channel attenuation coefficient, which provides a reliable prediction architecture for free space quantum communication channel estimation. Subsequently, root mean square error (RMSE), mean square error (MSE), mean absolute error (MAE) and coefficient of determination (R^2) are used to evaluate the prediction performance of the proposed model, which together provide a comprehensive assessment of the error size and fitting quality. Several typical models such as BPNN, LSTM, GRU, Transformer, TCN-Transformer and Transformer-Cross Attention are compared to verify the effectiveness of the proposed fusion strategy. The experimental results show that the TTC model consistently achieves the best overall performance in different prediction ranges. In the one-step prediction task, the R^2 of the proposed method is 95.68 % and the RMSE is 0.0915, indicating that the predicted value is highly consistent with the actual channel attenuation coefficient. The results show that the fusion of local time feature extraction, global dependency modeling and adaptive feature association interaction can significantly improve the prediction accuracy of

atmospheric channel parameters. In the two-step and three-step prediction tasks, although the prediction uncertainty increases naturally with the extension of the prediction time domain, the proposed model still maintains stable performance, relatively low error level and strong fitting ability. These results confirm that the TTC architecture not only performs well in real-time forecasting, but also maintains robust short-term trend forecasting capabilities under more challenging multi-step conditions. Further comparison with other neural network models reveals the specific advantages of the proposed design. Compared with BPNN, the TTC model has a stronger ability to characterize the nonlinear time evolution of meteorological data. Compared with loop architectures such as LSTM and GRU, it more effectively integrates local mutation learning and long-range dependence modeling, thereby reducing prediction errors and improving goodness of fit. Compared with the standard Transformer model, the introduced TCN branch enhances the extraction of local multi-scale patterns that may be underemphasized by using self-attention alone. In addition, compared with the mixed variants such as TCN-Transformer and Transformer-Cross Attention, the proposed method has achieved the best results in error-related indicators and fitting indicators, which further verifies the necessity and effectiveness of combining TCN, Transformer and Cross-Attention into a unified fusion framework for atmospheric attenuation coefficient prediction. In general, the TTC model proposed in this paper provides an effective solution for the estimation and short-term prediction of atmospheric channel attenuation coefficient in free space quantum communication. Its ability to jointly model local time structure, global sequence dependence and adaptive feature interaction can achieve accurate and stable prediction in different prediction horizons. The results show that the proposed framework has considerable potential in channel attenuation estimation, link state prediction and transmission state evaluation, which can provide useful technical support for improving the reliability and environmental adaptability of free space quantum communication systems.

Key words: Free-space quantum communication; Deep learning; Attenuation coefficient prediction; Attention mechanism; Transformer

OCIS Codes: 010.1300; 010.3920; 010.7295; 060.5565

CSTR: 32255.14.gzxb20265507.0727001