

融合兴趣点和联合损失函数的长时航迹预测模型

周传鑫 简刚* 李凌书 杨壹 胡宇 刘正铭
张伟 饶真珍 李云霄 吴超
(西南电子电信所 成都 610000)

摘要: 航迹预测在飞机舰船交通管理、路径规划和安全监测等领域具有重要意义。针对现有Transformer模型在航迹预测任务中存在的训练收敛速度慢、模型过拟合、长时误差大等问题, 该文提出一种融合兴趣点和联合损失函数的长时航迹预测模型(PL-Transformer)。首先, 通过专家经验定义预测范围内兴趣点的位置, 引入航迹范围内待预测轨迹点与兴趣点间的关联特征, 联合已有特征并转化为数据特征的稀疏表示, 增强模型对运动航迹的全局特征捕捉能力, 解决Transformer模型仅关注航迹自身局部特征变化的问题; 其次, 通过优化损失函数, 将模型经纬度特征与兴趣点特征损失相关联, 挖掘不同特征间的内涵损失, 从而提高对航迹的长时预测精度。实验结果表明, PL-Transformer模型在较长时间尺度的航迹预测任务中, 相较于基准长时模型预测误差平均降低了约10%, 验证了该模型在航迹预测中的有效性与可靠性。

关键词: 航迹预测; Transformer; 兴趣点; 损失函数优化

中图分类号: TN919.81; TP391.41

文献标识码: A

文章编号: 1009-5896(2025)08-2841-09

DOI: 10.11999/JEIT250011

CSTR: 32379.14.JEIT250011

1 引言

传统航迹预测方法在处理复杂、非线性的航迹数据时表现出明显局限性, 难以满足实际应用的需求。如卡尔曼滤波仅在满足线性和高斯假设的情况下表现优异, 对于非线性或非高斯噪声的航迹数据则无能为力; 马尔可夫链通过当前状态的概率分布和转移概率矩阵来预测下一时刻的状态分布, 这种机制使得模型无法充分考虑长时间历史数据对预测准确性的影响^[1-4]。

近年来, 深度学习技术在航迹预测任务中表现出较大优势, 特别是长短期记忆网络(Long Short-Term Memory, LSTM)、门控循环单元(Gated Recurrent Unit, GRU)、卷积神经网络(Convolutional Neural Network, CNN)、时序卷积网络(Temporal Convolutional Network, TCN)等模型在处理时间序列特征方面取得了显著效果。如张鹏等人^[5]在研究中利用CNN-LSTM模型对快速存取记录器(Quick Access Recorder, QAR)数据进行特征提取与预测, 证明了CNN-LSTM模型在飞机航迹预测中相较于传统方法的有效性; 谢国等人^[6]基于CNN和LSTM搭建模型实现了在车辆行驶场景下较为准确的航迹预测; Nan等人^[7]通过TCN-Attention-GRU模型对船舶航迹预测进行研究, 发现GRU与TCN结合并融入注意力机制后, 能有效提升船舶航迹预测的准确性。另外, Amin等人^[8]提出的基于

CNN-GRU和3D-CNN的混合深度学习模型在4D飞行航迹预测中也取得了较高的预测精度。

然而, LSTM和GRU等模型存在计算效率低、难以处理长时间依赖等问题, CNN和TCN也难以捕捉航迹数据的全局时空特征。Transformer架构凭借其自注意力机制在捕捉长时间依赖关系和并行化处理方面的优势, 逐渐被引入航迹预测领域^[9,10]。如Kumari等人^[8]在研究中提出的TrajectoFormer, 将Transformer应用于自动驾驶车辆的航迹预测, 构建了一个基于Transformer的时空关系模型, 并在实验中取得了较高的准确性; 同时, Sahfienya等人^[11]探讨了Transformer在复杂交通场景中的应用, 展示了该模型在多航迹预测方面的潜力。

TrAISformer^[12]是最新提出的一种专为航迹预测任务设计的Transformer模型架构, 其在公开数据集上取得了较为优异的预测效果, 特别是中长期的航迹预测场景下表现突出。但是, TrAISformer模型在捕捉航迹数据的异质性和多样性特征方面仍有不足, 模型对多维度数据的特征提取能力仍有提升空间。

为此, 本文在TrAISformer模型基础上提出了一种基于兴趣点和联合损失函数的长时航迹预测模型(Point Loss-Transformer, PL-Transformer), 通过专家经验定义预测范围内兴趣点的位置, 引入待预测轨迹点与兴趣点间的关联特征, 联合已有特征并转化为数据特征的稀疏表示, 增强模型对运动航迹的全局特征捕捉能力, 解决Transformer模型仅能关注航迹自身局部特征变化的问题; 同时, 通过

设计联合损失函数,将模型经纬度特征与兴趣点特征损失相关联,挖掘不同特征间的内涵损失,从而提高对航迹的长时预测精度。实验结果表明,PL-Transformer在多项评价指标上均优于TrAISformer模型、GRU模型和LSTM模型,本文展示了PL-Transformer在航迹预测任务中的应用潜力。

2 PL-Transformer模型

2.1 整体结构

在PL-Transformer模型中,航迹预测任务从回归问题被转化为多分类问题,对每个时间步的航迹数据特征分别进行预测。如图1所示,PL-Transformer模型将已知轨迹和真实航迹转换成预测空间中的栅格点迹,预测航迹同样也是预测空间中的栅格点,当预测航迹的栅格点与真实航迹的栅格点一致时,表示模型预测结果正确。从回归问题变成多分类问题的过程使模型输出结果更加可控,预测的精度和稳定性显著提升。

PL-Transformer模型主要包括数据特征稀疏表示模块、基于兴趣点的特征工程模块、Transformer结构模块、损失函数优化模块4个部分,下面将分别介绍。

2.2 数据特征稀疏表示

在航迹预测领域,一个核心难题是如何利用较少的数据维度来拟合运动目标的多样性和复杂性。为此,本文借鉴文献[12]将数据特征进行稀疏表示,将较少的数据维度映射到更高维度的空间向量中,解决数据本身的多样性问题。

数据特征稀疏表示的核心是先将原始数据 x_t 转换为分类任务需要的One-hot编码向量 h_t ,然后再通过Embedding层映射到更加高维、稀疏的向量空间 e_t 中,再输入Transformer模型中,获得下一时刻的预测概率分布 p_{t+1} ,如图2所示。

(1)one-hot编码:原始数据中的每个数据点(包括经纬度、速度和航向)都被离散化到不同的区间,




图1 PL-Transformer模型预测过程




图2 数据特征稀疏表示

并转换为one-hot编码表示。设原始数据点为 $x = (lat, lon, sog, cog)$,代表(经度、纬度、速度、航向),将每个特征按照预设的区间进行离散化处理。例如,将经度 lat 分割为 N_{lat} 个区间,其余维度同理,假设经度最小值为 10° ,最大值为 15° ,按照 0.1° 的精度进行分割后,经度范围被切分为50个区间范围内。对于每个特征维度,根据其实际数值所处的位置,直接用对应的离散区间编号表示。通过这种方式,原始数据点将被转换为一个更高维度的one-hot编码表示

$$h_t = (h_t^{lat}, h_t^{lon}, h_t^{sog}, h_t^{cog}) \quad (1)$$

(2)Embedding向量:完成离散化表示后,模型通过嵌入层Embedding将这些离散化的数值映射到一个连续的高维向量空间,形成嵌入向量。嵌入过程可以表示为

$$e_t = W[h_t] \quad (2)$$

其中, W 将是每个特征的嵌入矩阵,通过这一操作,所有特征都会被映射到相同的高维向量空间。

最终,嵌入向量 $e = [e_{lat}, e_{lon}, e_{sog}, e_{cog}]$ 将作为模型的输入,传递到后续的Transformer模型中,以捕捉航迹数据中的复杂特征和长期依赖关系。

2.3 基于兴趣点的特征工程

兴趣点在本文中指的是航迹预测空间内预测目标特别关注的若干地理坐标,其具体位置的设定依赖于专家经验,例如飞机舰船在通航过程中途经的机场、港口和岛礁等环境信息,敌方军事目标在执行任务区域内的重要关注对象。在数据量充分的情况下,飞机舰船的海量航行轨迹中必然蕴含着兴趣点的内涵信息,基于此想法,该文通过基于兴趣点的特征工程改进,引入额外的特征来增强模型对航迹数据的全局特征捕捉能力,解决Transformer在航迹预测过程中仅关注自身航迹特征变化的问题。

具体而言,在每个数据点的基础上,新增了两个重要的特征维度:

(1)到兴趣点的距离:定义兴趣点 $\mathbf{x}_q = (\text{lat}_q, \text{lon}_q)$,计算每个航迹点与兴趣点之间的欧氏距离,作为特征输入,每个航迹点 $\mathbf{x}_i$ 与兴趣点 $\mathbf{x}_q$ 之间的 d_i 距离计算为

$$d_i = \|\mathbf{x}_i - \mathbf{x}_q\|_2 \quad (3)$$

该特征可以帮助模型更好地理解运动目标相对于兴趣点的位置,从而增强模型对航迹全局运动趋势的捕捉能力。

(2)到兴趣点的方向角:为了进一步提升模型对航迹方向性变化的捕捉能力,本文引入了方向角特征。首先,计算当前航迹点 $\mathbf{x}_i$ 与前一个航迹点 $\mathbf{x}_{i-1}$ 之间的方向向量 $\mathbf{v}_i$

$$\mathbf{v}_i = \mathbf{x}_i - \mathbf{x}_{i-1} = (\text{lat}_i - \text{lat}_{i-1}, \text{lon}_i - \text{lon}_{i-1}) \quad (4)$$

然后,计算当前航迹点 $\mathbf{x}_i$ 与兴趣点 $\mathbf{x}_q$ 之间的方向向量 $\mathbf{u}_i$

$$\mathbf{u}_i = \mathbf{x}_q - \mathbf{x}_i = (\text{lat}_q - \text{lat}_i, \text{lon}_q - \text{lon}_i) \quad (5)$$

方向角 θ_i 表示 $\mathbf{v}_i$ 与 $\mathbf{u}_i$ 的夹角,可以通过它们的点积来计算

$$\theta_i = \arccos\left(\frac{\mathbf{v}_i \cdot \mathbf{u}_i}{\|\mathbf{v}_i\| \|\mathbf{u}_i\|}\right) \quad (6)$$

通过将上述两个新增特征引入模型,PL-Transformer能够更全面地捕捉航迹数据中的全局位置与方向性变化特征,从而进一步提升模型在航迹预测任务中的准确性与稳定性。

综上所述,当航迹预测空间中包含兴趣点为A和B时,航迹点 i, j 和 k 分别新增4个特征,分别是其到兴趣点A的距离和方向角、到兴趣点B的距离和方向角,如图3所示。

2.4 Transformer结构

PL-Transformer模型的结构由多个部分组成,




图3 航迹预测空间中的兴趣点

主要包括嵌入层、Transformer编码器及输出层。首先,嵌入层将输入数据进行高维表示并输入到Transformer编码器中。Transformer编码器由多层网络堆叠组成,每一层都包含多头自注意力机制和前馈神经网络,能够同时处理输入数据的所有时间步长,从而有效地捕捉航迹的长时间依赖关系和复杂的时空模式。在经过多层Transformer编码器处理后,模型将通过一个全连接层最终预测出未来的航迹点。

Transformer网络每一层作为一个自回归模型,采用了多头自我注意力机制

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_e}}\right) \mathbf{V} \quad (7)$$

其中, $\mathbf{Q}, \mathbf{K}$ 和 $\mathbf{V}$ 是输入序列的线性投影, $\sqrt{d_e}$ 是模型层的维度大小。在每一层中,输入序列被投影到新的空间 $\mathbf{V}$ 中,并且注意力模块的输出是在 $\mathbf{V}$ 中的加权和,其中权重表示每个时间步相对贡献的量。这些权重通过 $\mathbf{Q}$ 和 $\mathbf{K}$ 的点积进行softmax计算,并归一化以 $\sqrt{d_e}$ 为分母得到。 $\mathbf{Q}, \mathbf{K}$ 和 $\mathbf{V}$ 在训练阶段计算过程并行执行,其并行处理能力使得模型能够同时从多个过去的时刻中检索信息。

Transformer的最终层输出是一个与式(1)中 $\mathbf{h}_t$ 相同维度的向量 $\mathbf{p}_t^{\text{pre}}$ 。在下一节中,将展示PL-Transformer模型如何利用这个输出来进行训练与优化,以实现对未来位置的精确预测。

2.5 联合损失函数

PL-Transformer模型对原始数据的每个特征应用交叉熵损失来进行优化。其损失函数设计为

$$L_{\text{CE}}^{(t)} = \text{CE}(\mathbf{h}_t, \mathbf{p}_t) \quad (8)$$

其中, $\mathbf{h}_t$ 表示目标在时间步 t 的one-hot编码, $\mathbf{p}_t$ 表示模型在时间步 t 对应的预测概率分布。

在2.3节中,引入了两个新的特征:到兴趣点的距离和方向角。然而,在本文中这两个新增特征的损失函数并非直接参与计算,而是通过经纬度输出的预测值间接体现。设模型输出的后两个维度为 $\hat{\mathbf{d}}$ 和 $\hat{\boldsymbol{\theta}}$,新增特征损失 $L_{\text{new}}^{(t)}$ 计算为

$$L_{\text{new}}^{(t)} = \text{CE}(\hat{\mathbf{d}}_t, \text{lat}_t) + \text{CE}(\hat{\boldsymbol{\theta}}_t, \text{lat}_t) + \text{CE}(\hat{\mathbf{d}}_t, \text{lon}_t) + \text{CE}(\hat{\boldsymbol{\theta}}_t, \text{lon}_t) \quad (9)$$

综上,PL-Transformer模型在每个时间步 t 下,联合损失包含两部分:原始特征损失 $L_{\text{CE}}^{(t)}$ 和新增特征损失 $L_{\text{new}}^{(t)}$ 。在PL-Transformer模型中,输入数据包含6个维度:经纬度、速度、方向、距离和方向角。模型的输出同样是6个维度,但与传统设计不同的是,模型输出的前4个维度与原始的经纬度、

速度和方向对应,而新增的两个维度则用于与经纬度的损失计算。最终的联合损失函数为

$$L^{(t)} = L_{CE}^{(t)} + \lambda L_{new}^{(t)} \quad (10)$$

结合上述步骤,PL-Transformer模型的伪代码如算法1所示。

3 实验结果与分析

3.1 实验环境与评价指标

本文使用了真实的自动相关监视广播(Automatic Dependent Surveillance-Broadcast, ADS-B)飞机航迹数据集TrajAir^[13]其中的111_day部分,该项目由Air Lab提供。该数据集收集了大量飞机在飞行过程中的航迹信息,包括经纬度(longitude and latitude)、地速(Ground Speed, GS)和航向(Heading)等动态特征。TrajAir数据集是在匹兹堡-巴特勒区域机场收集的,该机场是一个单跑道通用机场,位于宾夕法尼亚州匹兹堡市以北16 km,其所有的轨迹绘制如图4所示,在本文中,定义的兴趣点是机场中心点,也是飞机最关注的机场位置。

数据集经过预处理,去除了异常值和噪声,按固定时间间隔进行采样。同时,按照PL-Transformer模型的需求,额外计算了每个数据点到兴趣




图4 TrajAir数据集可视化展示

点的距离和方向角作为新增特征。最终数据集被划分为训练集、验证集和测试集,划分比例分别为70%, 20%和10%,学习率 $\eta=0.0006$ 。

实验在RTX2080-Ti-16G显存、16 GB内存、64位Windows 10操作系统环境下进行,深度学习框架使用PyTorch 2.01, CUDA版本为11.2,辅助工具包括NumPy和Pandas等数据处理库。

为了验证PL-Transformer模型在航迹预测任务中的性能,本文采用以下5个评价指标:

均方误差(Mean Squared Error, MSE): 用于评价模型预测值与真实值之间的平方差均值,越小表示模型误差越低,公式如式(11)。其中, $\hat{y}_i$ 表示预测的航迹点位置, y_i 表示航迹点的真实位置

$$MSE = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2 \quad (11)$$

平均绝对误差(Mean Absolute Error, MAE): 衡量模型预测值与真实值的平均绝对误差,数值越小表示模型预测精度越高,公式为

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (12)$$

中位绝对误差(Median Absolute Error, MdAE): 预测值与真实值之间差异的中位数,对异常值不如平均值敏感,能更稳定地反映模型性能,公式为

$$MdAE = \text{median}(|y_i - \hat{y}_i|) \quad (13)$$

决定系数(R^2): 衡量模型对数据变异性的解释程度,越接近1表示模型的解释能力越强,公式为

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (14)$$

平均绝对百分比误差(Mean Absolute Percentage Error, MAPE): 表示预测值与真实值之间的差异百分比,提供误差的相对大小,适用于需要评估误差比例的情况,公式为

算法1 PL-Transformer模型算法

输入: 训练集 $\{\mathbf{x}_{0:L}\}$, 训练模型参数 θ , 学习率 η , 分类区域 R , 速度sog, 方向角cog。

输出: 模型训练参数 θ 。

for $\mathbf{x}_{0:L}$ in $\{\mathbf{x}_{0:L}\}$ do

// 根据经纬度,计算与兴趣点A的距离和方向角

$d_i^A, \theta_i^A = R_{lat}, R_{lon}$

for t in 0: L do

// 对每个时刻向量进行one-hot编码

$\mathbf{h}_t = \text{onehot}(R_{lat}, R_{lon}, \text{cog}, \text{sog}, d_i^A, \theta_i^A)$

end

// embedding编码和transformer模型

$\mathbf{e}_t = \text{embedding}(\mathbf{h}_t)$

$\mathbf{p}_t = \text{transformer}(\mathbf{e}_t)$

// 损失计算

loss = 0

for l in 1: L do

loss = loss + $\ell(\mathbf{h}_l, \mathbf{p}_l)$

end

// 优化函数

$\theta = \text{AdamW}(\text{loss}, \theta, \mathbf{x}_{0:L})$

end

Return: θ

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (15)$$

3.2 收敛性分析

为了全面评估PL-Transformer模型在数据集上的收敛性能,本文对训练和验证损失的变化趋势进行了深入分析,并将结果与基准模型TrAISformer进行了对比。这些分析基于模型训练过程中的loss曲线(如图5所示),并结合了具体的数据点来展示两种模型的表现。

在初始阶段,PL-Transformer和对照模型TrAISformer都从一个较高的训练损失迅速收敛下降,呈现出明显的收敛特性。相比之下,PL-Transformer损失下降更加明显,收敛速度更快,尽管两者的损失函数不同导致没法进行数值上的比较,但从损失函数下降的幅度来看PL-Transformer模型在收敛性能上要优于TrAISformer模型。

此外,从图5中可以看出,PL-Transformer的损失曲线在第20轮就能达到较低的损失值,此时就可以停止模型训练。而TrAISformer需要大概50轮的训练才能让验证损失趋于稳定。这不仅反映了PL-Transformer较强的训练稳定性,还表明该模型能够更快地拟合数据,从而提升模型的训练速度。

综上,表明本文引入联合损失函数后,PL-Transformer模型在收敛速度和训练轮次上的表现要优于TrAISformer模型,具有更好的收敛平稳性和拟合数据的能力。

3.3 短期预测精度分析

为了评估 PL-Transformer 模型在飞机和船舶航迹预测任务中的精度表现,本文对比了 PL-Transformer, TrAISformer, LSTM和GRU 4个模型的预测结果。使用测试集上的数据进行多次独立预测,并基于多项指标进行了详细的精度分析。所使用的评估指标包括:均方误差(MSE)、平均绝对误差(MAE)、中位绝对误差(MdAE)、决定系数(R^2)以及平均绝对百分比误差(MAPE)。

在飞机数据集的短期航迹预测任务中,PL-Transformer模型与TrAISformer模型的整体表现相近,但显著好于LSTM和GRU模型,具体表现如下:(请注意,为了便于展示,本文将所有评估指标的值都增加1 000倍,保留3位小数,如表1所示。)

在MSE(均方误差)方面,PL-Transformer和TrAISformer模型的MSE值均为0.122,低于GRU模型的0.187和LSTM模型的0.255。这表明Transformer模型相较于其他两种模型具有更强的拟合能力。

在MAE(平均绝对误差)方面,PL-Transformer模型的MAE值为3.172,略大于TrAISformer模型的3.130显著低于GRU模型的6.484和LSTM模型的12.695。这表明PL-Transformer模型在MAE指标上的能力稍微有些损失,但几乎可以忽略不计。

在MdAE(中位绝对误差)方面,PL-Transformer模型的MdAE值为1.904,略大于TrAISformer模型的1.889,显著低于GRU模型的4.874和LSTM模型的10.663。这表明PL-Transformer 模型




图5 模型训练过程loss曲线图

表1 不同算法的评价指标值情况($\times 10^{-3}$)

指标	MSE	MAE	MdAE	R^2	MAPE
GRU	0.187	6.484	4.874	994.974	19.214
LSTM	0.255	12.695	10.663	996.164	54.235
TrAISformer	0.122	3.130	1.889	996.628	17.817
PL-Transformer	0.122	3.172	1.904	996.426	15.317

在MdAE指标上的能力稍微有些损失,但几乎可以忽略不计。

在 R^2 (决定系数)方面,PL-Transformer模型的 R^2 值为 996.426×10^{-3} ,略低于TrAISformer模型的 996.628×10^{-3} 。同时,4种模型均较为接近1,这表明4种深度学习模型在航迹预测任务上都具有对数据较强的解释能力。

在MAPE(平均绝对百分比误差)方面,PL-Transformer模型的MAPE值为15.317,略小于TrAISformer模型的17.817和GRU模型的19.214,显著低于LSTM模型的54.235。这表明通过引入联合损失函数,PL-Transformer模型在预测时的相对误差更小,具有更高的鲁棒性。

通过对飞机数据集的短期预测精度分析,可以看出,PL-Transformer模型在整体预测精度上与TrAISformer模型表现基本保持一致,在MAPE指标上较优于TrAISformer模型,在MAE, MdAE和 R^2 指标上略低于TrAISformer模型,而作为最常用的MSE指标,两者表现相同。这表明,引入兴趣点和损失函数优化后的PL-Transformer模型在相对误差控制和拟合度上具备较强的竞争力,仍保留了TrAISformer模型在复杂航迹预测任务中良好的稳定性和鲁棒性。

3.4 长期预测可视化分析

为了更直观地展示PL-Transformer模型在飞机航迹预测任务中的性能,本文进行了模型预测航迹与真实航迹的对比可视化分析,并通过多时间步预测的变化,展示了PL-Transformer与TrAISformer模型的预测效果。

本文选取了测试集中若干条航迹,将PL-Transformer模型的预测航迹与真实航迹进行了对比可视化,结果如图6所示,其中虚线代表实际航迹,散点线代表预测航迹,相同航迹颜色相同。结果显示,PL-Transformer模型的预测航迹在大多数区段紧密跟随真实航迹,特别是在航迹的复杂动态变化

区域表现出较高的适应性和精度,对于简单航段中也同样表现良好。

表2显示了PL-Transformer与TrAISformer模型在中长期预测任务(1~3 h)中的损失值,结果表明PL-Transformer的长期预测准确性优于TrAISformer模型。具体来看,PL-Transformer模型的损失从2.058(1 h)增加到5.561(3 h),相比之下,TrAISformer模型的损失从2.160(1 h)增加到6.145(3 h)。

3.5 时间复杂度分析

时间复杂度分析涉及3个主要过程:输入特征的处理、Transformer编码器计算以及联合损失计算,因此,与输入序列长度 N 、嵌入维度 d 以及Transformer层数 L 有关。

TrAISformer模型的时间复杂度集中在Transformer编码器的多头自注意力机制上,其每一层的计算复杂度为 $O(N^2 \cdot d)$,模型的总计算复杂度为 $O(L \cdot N^2 \cdot d)$ 。

PL-Transformer模型引入了距离和方向角两个新的特征维度,其输入特征从4个扩展到6个。这一变化影响了以下几个方面:

(1)特征处理过程:新增的特征通过嵌入层映射到高维空间,与原始特征一起作为模型输入。由于嵌入过程的复杂度通常是 $O(N \cdot d)$,输入特征维度的增加对总时间复杂度的影响很小。

(2)Transformer编码器的计算:由于主要计算复杂度取决于序列长度 N 和嵌入维度 d ,输入特征的增加(4~6个)不会显著改变Transformer编码器的复杂度,因此模型的总体计算复杂度依然保持为 $O(L \cdot N^2 \cdot d)$ 。

(3)联合损失函数:改进后的模型计算原始4维(经纬度、速度、航向)和新增特征(距离、方向角)的损失。虽然新增特征损失带来了额外的计算步骤,但由于损失计算的复杂度通常为 $O(N \cdot d)$,与Transformer编码器的复杂度相比,额外的损失计算对总体复杂度的影响可以忽略。




图6 航迹预测可视化

表 2 长期预测性能(km)

模型	1 h	2 h	3 h
TrAISformer	2.160	4.195	6.145
PL-Transformer	2.058	3.815	5.561

综上所述, PL-Transformer模型在引入特征工程和联合损失计算后, 虽然增加了额外的计算过程, 但对整体时间复杂度并没有产生显著影响。因此, 其总体计算复杂度仍然保持为 $O(L \cdot N^2 \cdot d)$, 与TrAISformer模型一致。

4 结束语

本文针对航迹预测任务中存在的复杂动态特征与异质性问题, 提出了一种基于兴趣点和损失函数优化的PL-Transformer模型。通过引入距离与方向角两项特征工程并设计联合损失函数, 使得模型能够更有效地学习与捕捉航迹数据中的空间与运动特征。实验结果表明, PL-Transformer模型在航迹预测任务中, 较AISformer模型以及其他常用的对比模型, 表现出了更高的预测精度、更快的收敛速度, 以及更强的鲁棒性, 特别是PL-Transformer模型在长时间跨度和复杂动态航迹预测任务中的优越性能。

但是, 尽管PL-Transformer模型在本实验中表现出色, 航迹预测任务在实际应用中仍然面临诸多挑战, 如数据噪声、航迹数据的高频变化、以及外部环境因素对航迹预测的影响等。未来的研究方向可以包括: 进一步提升模型对多模态航迹数据的适应能力, 结合多源信息以增强模型的泛化能力, 以及引入更多的特征工程与优化策略来应对更复杂的航迹预测任务。总之, 本文的研究工作为基于Transformer架构的航迹预测模型提供了一种有效的改进方法, 为航迹预测等实际应用场景提供了参考与借鉴^[14]。

参 考 文 献

- [1] SHUKLA P, SHUKLA S, and SINGH A K. Trajectory-prediction techniques for unmanned aerial vehicles (UAVs): A comprehensive survey[J]. *IEEE Communications Surveys & Tutorials*, 2025, 27(3): 1867–1910. doi: [10.1109/COMST.2024.3471671](https://doi.org/10.1109/COMST.2024.3471671).
- [2] LIU Mengmeng, CHENG Hao, CHEN Lin, *et al.* LAformer: Trajectory prediction for autonomous driving with lane-aware scene constraints[C]. The 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, Seattle, USA, 2024: 2039–2049. doi: [10.1109/cvprw63382.2024.00209](https://doi.org/10.1109/cvprw63382.2024.00209).
- [3] CONG Peichao, DENG Murong, XIAO Yixuan, *et al.* Trajectory prediction based on the dynamic characteristics and coupling relationships among vehicles in highway scenarios[J]. *Engineering Applications of Artificial Intelligence*, 2025, 140: 109718. doi: [10.1016/j.engappai.2024.109718](https://doi.org/10.1016/j.engappai.2024.109718).
- [4] SHIN G H and YANG H. Vessel trajectory prediction in harbors: A deep learning approach with maritime-based data preprocessing and Berthing Side Integration[J]. *Ocean Engineering*, 2025, 316: 119908. doi: [10.1016/j.oceaneng.2024.119908](https://doi.org/10.1016/j.oceaneng.2024.119908).
- [5] 张鹏, 杨涛, 刘亚楠, 等. 基于CNN-LSTM的QAR数据特征提取与预测[J]. 计算机应用研究, 2019, 36(10): 2958–2961. doi: [10.19734/j.issn.1001-3695.2018.04.0214](https://doi.org/10.19734/j.issn.1001-3695.2018.04.0214).
- [6] ZHANG Peng, YANG Tao, LIU Yanan, *et al.* Feature extraction and prediction of QAR data based on CNN-LSTM[J]. *Application Research of Computers*, 2019, 36(10): 2958–2961. doi: [10.19734/j.issn.1001-3695.2018.04.0214](https://doi.org/10.19734/j.issn.1001-3695.2018.04.0214).
- [7] XIE Guo, SHANG Gnqi, FEI Rong, *et al.* Motion trajectory prediction based on a CNN-LSTM sequential model[J]. *Science China Information Sciences*, 2020, 63(11): 212207. doi: [10.1007/s11432-019-2761-y](https://doi.org/10.1007/s11432-019-2761-y).
- [8] NAN Tian, CAO Wengeng, WANG Zhe, *et al.* Evaluation of shallow groundwater dynamics after water supplement in North China Plain based on attention-GRU model[J]. *Journal of Hydrology*, 2023, 625: 130085. doi: [10.1016/j.jhydrol.2023.130085](https://doi.org/10.1016/j.jhydrol.2023.130085).
- [9] AMIN F, GHARAMI K, and SEN B. TrajectoFormer: Transformer-based trajectory prediction of autonomous vehicles with spatio-temporal neighborhood considerations[J]. *International Journal of Computational Intelligence Systems*, 2024, 17(1): 87. doi: [10.1007/s44196-024-00410-1](https://doi.org/10.1007/s44196-024-00410-1).
- [10] VASWANI A, SHAZEER N, PARMAR N, *et al.* Attention is all you need[C]. The 31st International Conference on Neural Information Processing Systems, Long Beach, USA, 2017: 6000–6010.
- [11] 唐光旭. 基于Transformer和Bi-LSTM模型的船舶轨迹预测[J]. 珠江水运, 2024(17): 109–111. doi: [10.14125/j.cnki.zjsy.2024.17.024](https://doi.org/10.14125/j.cnki.zjsy.2024.17.024).
- [12] TANG Guangxu. Ship trajectory prediction based on Transformer and Bi-LSTM model[J]. *Pearl River Water Transport*, 2024(17): 109–111. doi: [10.14125/j.cnki.zjsy.2024.17.024](https://doi.org/10.14125/j.cnki.zjsy.2024.17.024).
- [13] SHAFIENYA H and REGAN A C. 4D flight trajectory prediction using a hybrid deep learning prediction method based on ADS-B technology: A case study of Hartsfield–Jackson Atlanta international airport (ATL)[J]. *Transportation Research Part C: Emerging Technologies*, 2022, 144: 103878. doi: [10.1016/j.trc.2022.103878](https://doi.org/10.1016/j.trc.2022.103878).

- [12] NGUYEN D and FABLET R. A transformer network with sparse augmented data representation and cross entropy loss for AIS-based vessel trajectory prediction[J]. *IEEE Access*, 2024, 12: 21596–21609. doi: [10.1109/ACCESS.2024.3349957](https://doi.org/10.1109/ACCESS.2024.3349957).
- [13] PATRIKAR J, MOON B, OH J, *et al.* Predicting like a pilot: Dataset and method to predict socially-aware aircraft trajectories in non-towered terminal airspace[C]. 2022 International Conference on Robotics and Automation (ICRA), Philadelphia, USA, 2022: 2525–2531. doi: [10.1109/ICRA46639.2022.9811972](https://doi.org/10.1109/ICRA46639.2022.9811972).
- [14] NGUYEN D, VADAINÉ R, HAJDUCH G, *et al.* *GeoTrackNet*—a maritime anomaly detector using probabilistic neural network representation of AIS tracks and a *contrario* detection[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(6): 5655–5667. doi: [10.1109/TITS.2021.3055614](https://doi.org/10.1109/TITS.2021.3055614).
- 周传鑫: 男, 硕士, 助理工程师, 研究方向为人工智能、大数据分析.
简 刚: 男, 硕士, 助理研究员, 研究方向为大数据分析、大模型.
李凌书: 男, 博士, 助理研究员, 研究方向为人工智能、大模型.
杨 壹: 男, 硕士, 助理工程师, 研究方向为人工智能、大模型.
胡 宇: 男, 硕士, 助理研究员, 研究方向为数据分析、人工智能.
刘正铭: 男, 硕士, 助理研究员, 研究方向为数据分析、深度学习.
张 伟: 男, 硕士, 副研究员, 研究方向为数据分析、人工智能.
饶真珍: 女, 硕士, 助理研究员, 研究方向为数据分析、深度学习.
李云霄: 男, 硕士, 助理研究员, 研究方向为数据分析、人工智能.
吴 超: 男, 硕士, 助理研究员, 研究方向为数据分析、深度学习.
- 责任编辑: 余 蓉

Long-Term Trajectory Prediction Model Based on Points of Interest and Joint Loss Function

ZHOU Chuanxin JIAN Gang LI Lingshu YANG Yi HU Yu

LIU Zhengming ZHANG Wei RAO Zhenzhen

LI Yunxiao WU Chao

(Southwest Electronics and Telecommunications Institute, Chengdu 610000, China)

Abstract:

Objective With the rapid development of modern maritime and aerospace sectors, trajectory prediction plays an increasingly critical role in applications such as ship scheduling, aviation, and security. Growing demand for higher prediction accuracy exposes limitations in traditional methods, such as Kalman filtering and Markov chains, which struggle with complex, nonlinear trajectory patterns and fail to meet practical needs. In recent years, deep learning techniques, including LSTM, GRU, CNN, and TCN models, have demonstrated notable advantages in trajectory prediction by effectively capturing time series features. However, these models still face challenges in representing the heterogeneity and diversity of trajectory data, with limited capacity to extract features from multidimensional inputs. To address these gaps, this study proposes a long-term trajectory prediction model, PL-Transformer, based on points of interest and a joint loss function.

Methods Building on the TrAISformer framework, the proposed PL-Transformer incorporates points of interest and a joint loss function to enhance long-term trajectory prediction. The model defines the positions of points of interest within the prediction range using expert knowledge and introduces correlation features between trajectory points and points of interest. These features are integrated into a sparse data representation that improves the model's ability to capture global trajectory patterns, addressing the limitation of conventional Transformer models, which primarily focus on local feature changes. Additionally, the model employs a joint loss function that links latitude and longitude predictions with feature losses associated with points of interest. This approach leverages inter-feature loss relationships to enhance the model's capability for accurate long-term trajectory prediction.

Results and Discussions The convergence performance of the PL-Transformer model is evaluated by analyzing the variation in training and validation losses and comparing them with those of the TrAISformer model. The corresponding loss curves are presented in (Fig. 5). The PL-Transformer model exhibits faster convergence and improved training stability on both datasets. These results indicate that the introduction of the joint loss function enhances convergence efficiency and training stability, yielding performance superior to the

TrAISformer model.

In terms of short-term prediction accuracy, the results in Table 1 show that the PL-Transformer model achieves comparable overall prediction accuracy to the TrAISformer model. The PL-Transformer model performs better in terms of the Mean Absolute Percentage Error (MAPE) metric, while it shows slightly higher errors than the TrAISformer model for Mean Absolute Error (MAE), median Absolute Error (MdAE), and coefficient of determination (R^2). For the widely used Mean Squared Error (MSE) metric, both models perform similarly. These results indicate that after incorporating points of interest and optimizing the loss function, the PL-Transformer model retains competitive performance in relative error control and fitting accuracy, while preserving the stability and robustness of the TrAISformer model in complex trajectory prediction tasks.

For long-term prediction visualization, Table 2 presents the loss values for both models across medium to long-term prediction horizons (1 to 3 h). The PL-Transformer model achieves better long-term prediction accuracy than the TrAISformer model. Specifically, the loss for the PL-Transformer model increases from 2.058 (1 h) to 5.561 (3 h), whereas the TrAISformer model's loss rises from 2.160 to 6.145 over the same period.

In terms of time complexity analysis, although the PL-Transformer model incorporates additional feature engineering and joint loss computation steps, these enhancements do not substantially increase the overall time complexity. The total computational complexity of the PL-Transformer model remains consistent with that of the TrAISformer model.

Conclusions This study proposes the PL-Transformer model, which incorporates points of interest and an optimized loss function to address the challenges posed by complex dynamic features and heterogeneity in trajectory prediction tasks. By introducing distance and bearing angle through feature engineering and designing a joint loss function, the model effectively learns and captures spatial and motion characteristics within trajectory data. Experimental results demonstrate that the PL-Transformer model achieves higher prediction accuracy, faster convergence, and greater robustness than the TrAISformer model and other widely used baseline models, particularly in long-term and complex dynamic trajectory prediction scenarios. Despite the strong performance of the PL-Transformer model in experimental settings, trajectory prediction tasks in real-world applications remain affected by various challenges, including data noise, high-frequency trajectory fluctuations, and the influence of external environmental factors. Future research will focus on improving the model's adaptability to multimodal trajectory data, integrating multi-source information to enhance generalization capability, and incorporating additional feature engineering and optimization strategies to address more complex prediction tasks. In summary, the proposed PL-Transformer model provides an effective advancement for Transformer-based trajectory prediction frameworks and offers valuable reference for practical applications in trajectory forecasting and related fields.

Key words: Trajectory prediction; Transformer; Points of interest; Loss function optimization