

时空双重提取与频域增强的飞行轨迹预测^①

骆晓宁¹, 王燕妮¹, 谷卓²

¹(西安建筑科技大学 信息与控制工程学院, 西安 710055)

²(陕西凌云科技有限责任公司, 西安 710119)

通信作者: 王燕妮, E-mail: wangyanni@xauat.edu.cn



摘要: 为有效应对飞行轨迹预测中存在的复杂时空特性以及时域波动对预测精度带来的挑战, 提出融合时空双重提取与频域增强的飞行轨迹预测方法. 该方法结合时间卷积网络 (TCN) 与 iTransformer 模型旨在同时捕捉飞行轨迹序列中的局部时序特征与全局变量交互关系, 从而在不同层次和粒度上实现对数据特征的双重提取, 有效挖掘其潜在的时空关联性. 随后引入频域增强通道注意力机制 (FECAM), 通过离散余弦变换将轨迹特征转化为频域, 并应用通道注意力机制强化转化后的频域信息, 以减少时域波动带来的影响. 实验基于三维飞行轨迹数据集, 在爬升、巡航及降落阶段, 该方法的平均绝对误差分别为 1.15、0.15 和 0.82. 结果表明相较于现有方法, 所提方法在预测精度和稳定性方面均具有明显优势.

关键词: 飞行轨迹预测; 时空双重特征提取模块; 频域增强通道注意力机制; iTransformer; 时间卷积网络

引用格式: 骆晓宁, 王燕妮, 谷卓. 时空双重提取与频域增强的飞行轨迹预测. 计算机系统应用, 2026, 35(1): 228–236. <http://www.c-s-a.org.cn/1003-3254/10048.html>

Spatio-temporal Dual Extraction and Frequency Enhanced Flight Trajectory Prediction

LUO Xiao-Ning¹, WANG Yan-Ni¹, GU Zhuo²

¹(College of Information and Control Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China)

²(Shaanxi Lingyun Technology Co. Ltd., Xi'an 710119, China)

Abstract: To address the complex spatiotemporal characteristics and temporal domain fluctuation challenges in flight trajectory prediction, this study proposes a method integrating spatiotemporal dual extraction and frequency-domain enhancement. The proposed method combines the temporal convolutional network (TCN) with the iTransformer model to capture local temporal features and global variable interactions in trajectory sequences. This enables dual extraction of data features at different levels and granularities, effectively uncovering potential spatiotemporal correlations. The frequency enhanced channel attention mechanism (FECAM) is introduced, which converts trajectory features into the frequency domain using the discrete cosine transform and strengthens the frequency-domain information with channel attention, reducing the impact of temporal domain fluctuations. Experiments on a 3D flight trajectory dataset show that during climb, cruise, and descent phases, the proposed method achieves mean absolute error of 1.15, 0.15, and 0.82, respectively, demonstrating significant advantages in prediction accuracy and stability over existing methods.

Key words: flight trajectory prediction; spatiotemporal dual feature extraction module (SDFEM); frequency enhanced channel attention mechanism (FECAM); iTransformer; temporal convolutional network (TCN)

① 基金项目: 陕西省自然科学基金基础研究计划 (2025JC-YBMS-791)

收稿时间: 2025-05-29; 修改时间: 2025-07-07; 采用时间: 2025-08-15; csa 在线出版时间: 2025-10-29

CNKI 网络首发时间: 2025-10-30

近年来,随着全球空中交通流量的快速增长,大型枢纽机场终端区区域的拥堵问题及飞行事故征候的发生率持续居高不下^[1].在我国,航空产业正处于快速发展阶段,与国家大力推动的低空经济发展密切相关.在此背景下,对低空领域精细化管理的需求日益迫切,亟需构建一套具备低成本、高精度和智能化特征的空中态势感知系统^[2],以保障飞行安全、提升空域运行效率.其中,飞行轨迹预测技术作为核心支撑手段,对于规避空中拥堵、优化航线决策及提升空域管理效能具有重要意义.

目前,针对民用航空器的飞行轨迹预测^[3]大致分为3类:状态估计法、动力学模型的方法、基于数据驱动的方法.状态估计方法将轨迹预测视为状态跟踪问题,通过状态估计与传播实现轨迹预测. Ayhan 等人^[4]利用隐马尔可夫模型学习历史轨迹、飞机规格型号和相关天气参数之间的关联,在考虑环境不确定性的条件下预测飞行轨迹,但该方法难以有效捕捉长时间运动状态的不确定性.动力学模型全面考量飞行器的性能参数,并基于此对飞行过程进行阶段性划分,进而建立相应的运动方程. Zhou 等人^[5]提出结合航空器动力学模型与灰色理论的方法,实现了实时轨迹预测.然而,由于其依赖理想化假设和难以获取的参数,实际应用中可能存在较大误差.相比之下,基于数据驱动的方法不依赖于具体的飞行器空气动力学参数,而是利用大量的历史轨迹数据来训练预测模型.田杉^[6]提出 CNN-LSTM 混合模型来挖掘轨迹数据的模式特征,在单步预测和多步预测中均取得了良好的效果.严皓^[7]将神经网络与注意力机制、自回归移动平均模型进行整合,通过对航迹聚类分析提升预测精度,其结果在多个维度上优于传统模型.

随着神经网络技术的不断发展,轨迹预测研究逐渐由改进传统算法转向基于深度学习的模型构建.翟文鹏等^[8]将 Transformer 模型与 GRU 网络相结合,对航迹数据中复杂的时序关系进行建模,显著提升了预测模型性能. Dong 等人^[9]提出了一种基于时间卷积网络 (temporal convolutional network, TCN) 和 Informer 模型的进阶阶段飞行轨迹预测方法,该模型首先利用 TCN 对预处理后的飞行数据进行时空维度的特征提取,然后采用 Informer 模型来执行提取的特征,并通过真实飞行数据验证了所提架构的有效性.飞行轨迹预测本质上是面向多变量时间序列的建模任务.此类数

据不仅在时间维度上表现出强相关性,各变量之间亦存在复杂的耦合关系.针对这一问题, Liu 等人^[10]提出了一种改进的 Transformer 模型——iTransformer,该模型采用纯编码器结构,在原有 Transformer 基础上进行优化,并被证实其性能优于现有的主流时间序列预测方法. Ren 等人^[11]提出了一种基于图注意力网络 (GAT) 与 iTransformer 的多尺度混合预测方法,有效提升了模型对不同粒度时间序列趋势的捕捉能力. Xie 等人^[12]则结合模糊 C 均值聚类算法对数据子集进行划分,并采用 iTransformer-TCN 模型对每个子集进行建模和预测,从而提高了光伏功率预测的精度.

尽管神经网络具备强大的建模能力,飞行轨迹数据在时域上仍表现出较强的波动性,给建模带来挑战.为应对这一问题,研究者开始探索将频域信息与注意力机制相结合的新路径. Zhou 等人^[13]提出了一种频域增强分解结构,对时间序列进行分解,并将傅立叶增强模块和小波增强模块集成到变压器的编码器和解码器中.施黄凯等人^[14]在 Transformer 架构基础上提出一种融合时频域信息与多尺度对抗训练的目标轨迹预测方法,通过嵌入小波分解实现时频域自适应滤波,并与时空注意力机制融合,增强了对长期趋势特征的建模能力.与简单地提取频域信息相比,将频域特征与时域上下文建模有机结合已成为当前时间序列预测领域的重要发展方向.

考虑到飞行轨迹数据在时空维度上的复杂性及其时域波动对预测结果的干扰,本文提出了一种融合时空双重提取与频域增强的飞行轨迹预测方法 (spatio-temporal dual extraction and frequency enhanced flight trajectory prediction method, SDFE-FPM),旨在提升预测精度与模型鲁棒性.本文的主要贡献如下.

(1) 设计时空双重特征提取模块 (spatiotemporal dual feature extraction module, SDFEM) 以学习捕捉序列之间的全局和局部动态特征,以求在不同层次和粒度上对数据特征实现双重提取.

(2) 引入了频域增强通道注意力机制 (frequency enhanced channel attention mechanism, FECAM),提取飞行轨迹数据集的频域信息,并与时域上下文依赖融合,提升飞行轨迹预测精度.

(3) 在飞行轨迹预测任务中验证所提模型的有效性与鲁棒性,并与当前主流方法进行对比实验,结果表明本文方法在多种评估指标下均具有明显优势.

1 相关工作

1.1 iTransformer 模型

飞行轨迹序列包含经度、纬度、高度等多个变量, 这些变量之间存在复杂的相互依赖关系. 目前, 从飞行轨迹序列数据中有效提取多变量特征依然是一个显著的技术挑战. 传统的 Transformer 模型在处理多个变量时, 由于其嵌入的是每个时间的多个变量, 这可能无法充分保留多元数据间的复杂关联性^[15], 从而影响了飞行轨迹重要特征的捕捉能力. 为了解决该问题, 引入 iTransformer 模型, 如图 1 所示, 由嵌入层 (embedding)、iTransformer 块 (TrmBlock) 和投影层 (projection) 组成.

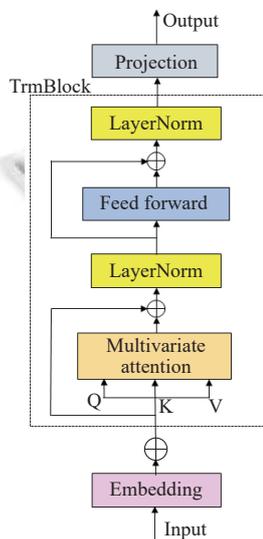


图 1 iTransformer 模型结构图

(1) 嵌入层 (embedding). 将时间序列数据输入至 iTransformer 模型中, 嵌入层将每个变量时间序列独立地嵌入为一个标记^[15].

(2) iTransformer 块 (TrmBlock). 由多头自注意力、前馈网络和层归一化模块组成. 通过对独立嵌入的多变量计算注意力分布值, 多元注意力机制 (multivariate attention) 能够在同一时间点上评估各个变量的重要性, 并赋予关键特征更高的权重, 这使得模型能够捕捉到不同变量之间的复杂依赖关系, 提高了对多变量时间序列数据的理解力^[16]. 前馈网络 (feed forward) 用于提取每个标记的序列表示以增强模型的表达能力. 层归一化 (LayerNorm) 将数据规范化, 缩小了不同变量之间的数值范围差异, 确保每个特征在训练过程中具有相似的重要性, 这促进了更稳定的训练过程.

(3) 投影层 (projection). 在经过多个 TrmBlock 处理后, 特征表示可能变得非常丰富和复杂. 投影层由多层感知器组成, 其主要作用是对于这些特征进行降维或变换. 该模块对编码器模块独立处理后的多量标记进行非线性映射输出.

1.2 TCN

为弥补 iTransformer 模型难以有效保留和利用飞行轨迹数据中的局部动态变化信息的问题, 引入 TCN, 该网络因其特有的因果膨胀卷积结构对于捕捉飞行轨迹中的复杂动态变化至关重要, 已发展成为处理时序数据建模任务中的一种强有力的方法. 其核心架构包括以下 3 个主要组成部分.

(1) 因果卷积. 因果卷积确保了模型在预测时刻 t 的输出 $y(t)$ 只依赖于时刻 t 及之前的 k 个数据, 而不依赖于未来的数据点^[17]. 这一点对于时序预测任务非常重要, 因为在实际应用中无法预知未来的信息. 其公式如式 (1) 所示. 其中, f 是卷积核, k 是卷积核大小, x 是输入序列.

$$y(t) = \sum_{i=0}^{k-1} x(t-i) f(i) \quad (1)$$

(2) 膨胀卷积. 膨胀卷积是在卷积核之间插入空隙, 即跳过某些输入单元. 通过引入膨胀参数 d , 网络可以在不增加模型复杂度的情况下扩大感受野, 这提升了模型的效率和表达能力^[18]. 其公式如式 (2) 所示, d 决定了卷积核中元素之间的间距.

$$y(t) = \sum_{i=0}^{k-1} x(t-d \times i) f(i) \quad (2)$$

(3) 残差连接. 当残差输入和输出具有不同的维度时, 会添加一个 1×1 的卷积. 残差学习为 TCN 提供了在深层结构下更稳定的训练途径, 缓解了时序序列预测任务中常见的梯度消失问题^[19]. 残差方法如式 (3) 所示:

$$output = input(input) + F(input) \quad (3)$$

1.3 离散余弦变换

对于飞行轨迹数据在时域上表现出的强烈波动性和不稳定问题, 一些研究者利用傅立叶变换 (Fourier transform, FT) 等方法将时序序列变换到频域并提取特征^[20]. 但是, FT 由于周期性问题, 会不正确地引入高频分量, 而这会导致边界信息出现误差值从而使模型难

以正确提取飞行轨迹序列间的信息. 为了应对上述情况, 本研究中应用离散余弦变换 (discrete cosine transform, *DCT*).

DCT 本质上是从离散傅立叶变换中提取出来的实数部分, 并且只考虑了偶对称性, 因此它能够有效地避免产生不必要的复数成分和低频分量^[21]. 一个长度为 L 的离散序列, 其 *DCT* 系数计算公式如式 (4) 所示:

$$x(k) = \sqrt{\frac{2}{n}} \sum_{n=0}^{L-1} x[n] \cos\left(\frac{\pi}{L}\left(n + \frac{1}{2}\right)k\right) \quad (4)$$

其中, $k = 1, 2, \dots, L-1$. $x(k)$ 为原始序列 $x[n]$ 在频域中的表示, 即该序列可以被表达为多个不同频率的余弦波的线性组合.

2 本文方法

2.1 问题描述

飞行轨迹预测任务中, 可将其形式化定义一个序列预测问题: 给定飞行器在前 L 个时间步内的状态序

列, 其中每个时间步包括经度、纬度和高度等状态信息, 模型需预测未来 T 个时间步内飞行器的状态信息. 具体而言, 在某一时刻 t , 模型的输入为从 $t-L$ 至 t 的历史状态序列, 输出为目标飞行器在 $t+1$ 至 $t+T$ 时间步内的未来状态序列^[22].

2.2 整体架构

为解决飞行轨迹数据所具有的复杂时空特性难以被充分建模与提取, 且在时间维度上表现出强烈波动动态性的问题, 本文提出 SDFE-FPM. 模型结构如图 2 所示, 其整体可分为两个模块: SDFEM 和 FECAM.

2.2.1 SDFEM

飞行轨迹数据具有显著的时空特性, 从时间维度来看, 飞行器的状态参数 (如位置、速度、高度等) 随时间变化构成非线性时序序列; 从空间维度来看, 多个变量 (如经度、纬度、高度等) 之间存在复杂的相互依赖关系. 此外, 飞行行为还受到短期局部波动、中期航向调整及长期全局趋势等多种因素的影响.

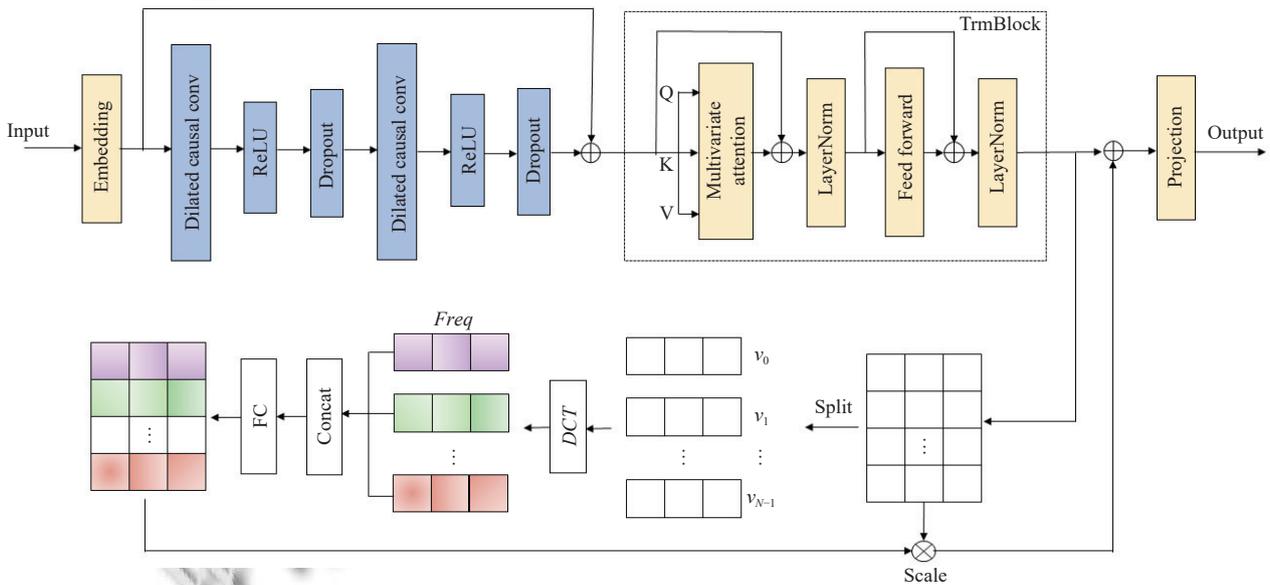


图 2 融合时空双重提取与频域增强的飞行轨迹预测方法

针对飞行轨迹数据的上述特性, 本文提出 SDFEM, 旨在融合局部感知与全局建模能力, 以提升其对飞行轨迹多尺度动态行为的建模能力. 该模块采用级联式融合结构, 在统一框架下实现对飞行轨迹数据特征在不同层次和粒度上的双重提取, 从而增强模型对复杂飞行行为的适应能力, 突破传统单一建模方法在处理多尺度飞行轨迹数据时存在的建模片面性和泛化能力不足的问题.

首先, 通过嵌入层对原始飞行轨迹数据进行编码, 将每个变量的时间序列独立映射为标记 (token) 表示. 此时输入维度由原始的 $B \times L \times N$ 转换为 $B \times N \times E$, 其中 B 表示批次大小, L 为输入序列的长度, N 为变量的数量, E 为模型的维度.

随后, 嵌入后的轨迹序列被输入至包含两个 TemporalBlock 的网络模块中. 该模块采用因果膨胀卷积 (dilated causal convolution) 结构, 能够在不引入未来

信息的前提下,有效提取不同尺度上的局部特征^[23]. 每个 TemporalBlock 包含两层一维因果膨胀卷积,每层卷积后依次接 ReLU 激活函数与 Dropout 层以引入非线性层防止过拟合. 如图 3 所示,本文因果膨胀卷积网络设置卷积核大小为 3,并固定步长为 1. 第 1 层填充为 1,膨胀率为 1 实现标准卷积效果. 第 2 层填充为 2,膨胀率为 2,使得卷积操作在间隔的数据点上进行,从而在不增加参数数量的情况下覆盖更大的输入范围. 最终通过残差连接将输入信息传递至深层,增强模型的学习能力. 在此基础上,进一步引入 TrmBlock 块,以提升变量间的非线性耦合建模效果,并增强对多变量交互关系的全局建模能力.

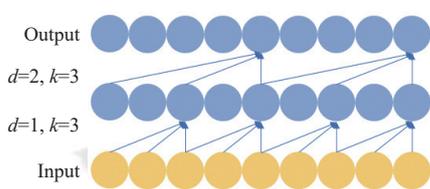


图 3 因果膨胀卷积图

如图 4 所示, multivariate attention 通过对时间序列表示进行全方位提取,并利用线性投影获取查询(Q)、键(K)、值(V)矩阵,进而计算出前 Softmax 分数,以揭示变量之间的相关性^[24]. 这一步骤对于理解多元数据内部关系至关重要.

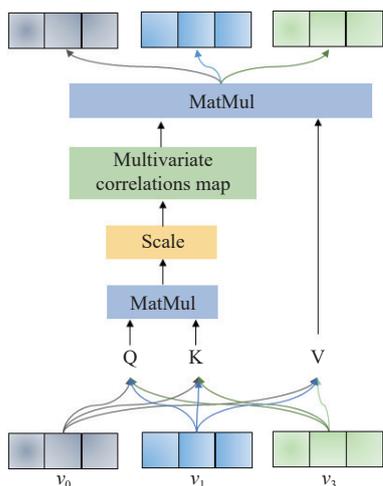


图 4 Multivariate attention 结构

此外, TrmBlock 中还包含一个 feed forward,其结构如图 5 所示,主要包括两层一维卷积操作和激活函数,其中第 1 层用于编码历史时间数据,第 2 层用于解码并进行预测.

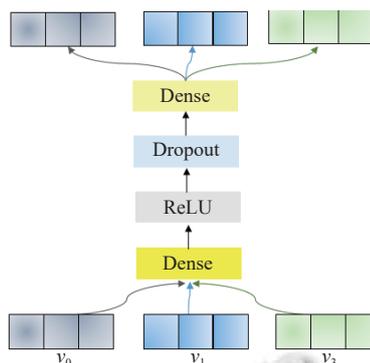


图 5 Feed forward 结构图

整个过程中, LayerNorm 被应用于各子模块之间,以提升模型的稳定性与泛化能力,其数学表达式见式 (5).

$$LayerNorm(H) = \left\{ \frac{h_n - Mean(h_n)}{\sqrt{Var(h_n)}} \mid n = 1, 2, \dots, N \right\} \quad (5)$$

2.2.2 FECAM

如图 6 所示,飞行轨迹数据通常蕴含丰富的频率成分,其中大多数能量集中在较低频段,表明低频特征对轨迹趋势建模具有重要意义. 尽管 SDFEM 能够有效捕捉时间序列中的全局与局部特征,但其建模过程主要局限于时域,未能充分挖掘频域信息. 而在飞行轨迹预测任务中,频域特征对于揭示运动趋势具有重要意义.

为进一步挖掘频域信息并抑制时域波动带来的干扰,本文在 SDFEM 后引入 FECAM^[25],该模块通过将离散余弦变换(DCT)嵌入特征提取网络,提取低频成分;随后,在频域空间应用通道注意力机制,建模不同频段间的相关性,从而提取更具代表性的趋势特征,进一步增强对低频长期趋势的感知能力. 该模块不仅保留了原始数据的时序特性,同时提供了更为丰富的频域特征表示. 将飞行轨迹数据输入至 SDFEM 中,从而获得其时域特征表示.

如图 2 所示,沿着通道维度对这些特征映射执行分割操作,将其划分为 N 个子组,每个子组包含 C 个通道,随后,对每一子组分别应用 DCT,获得其对应频谱表示:

$$Freq_j = DCT_k(V_j) = \sqrt{\frac{2}{L}} \sum_{n=0}^{L-1} V_j[n] \cos\left(\frac{\pi}{L} \left(n + \frac{1}{2}\right) k\right) \quad (6)$$

其中, $k = 0, 1, \dots, L-1$, $j = 0, 1, \dots, N-1$. N 是通道的数量, L 是时间序列的长度. 完成 DCT 变换后,将所有子组的频谱特征进行拼接,形成一个综合的频率特征

向量 $Freq$, 作为后续的输出。

$$Freq = DCT(V) = \text{concat}([Freq_0, Freq_1, \dots, Freq_{N-1}]) \quad (7)$$

然而, 仅依赖频谱信息可能导致时域特征的部分丢失, 为此引入一个基于 squeeze-and-excitation 块^[26]的注意力机制, 用于动态学习各通道的重要性权重, 从而在保留频域特征的同时, 增强关键时域信息的表达

能力。

$$F_c - att = \sigma(w_2 \delta(w_1 DCT(V))) \quad (8)$$

其中, w_1 和 w_2 分别是全连接层的权重矩阵, δ 表示 ReLU 激活函数, σ 表示 Sigmoid 激活函数。

通过这种方式, 每个通道特征与每个频率成分之间的相互作用得到了加强, 从而鼓励网络提升特征提取的多样性和鲁棒性。

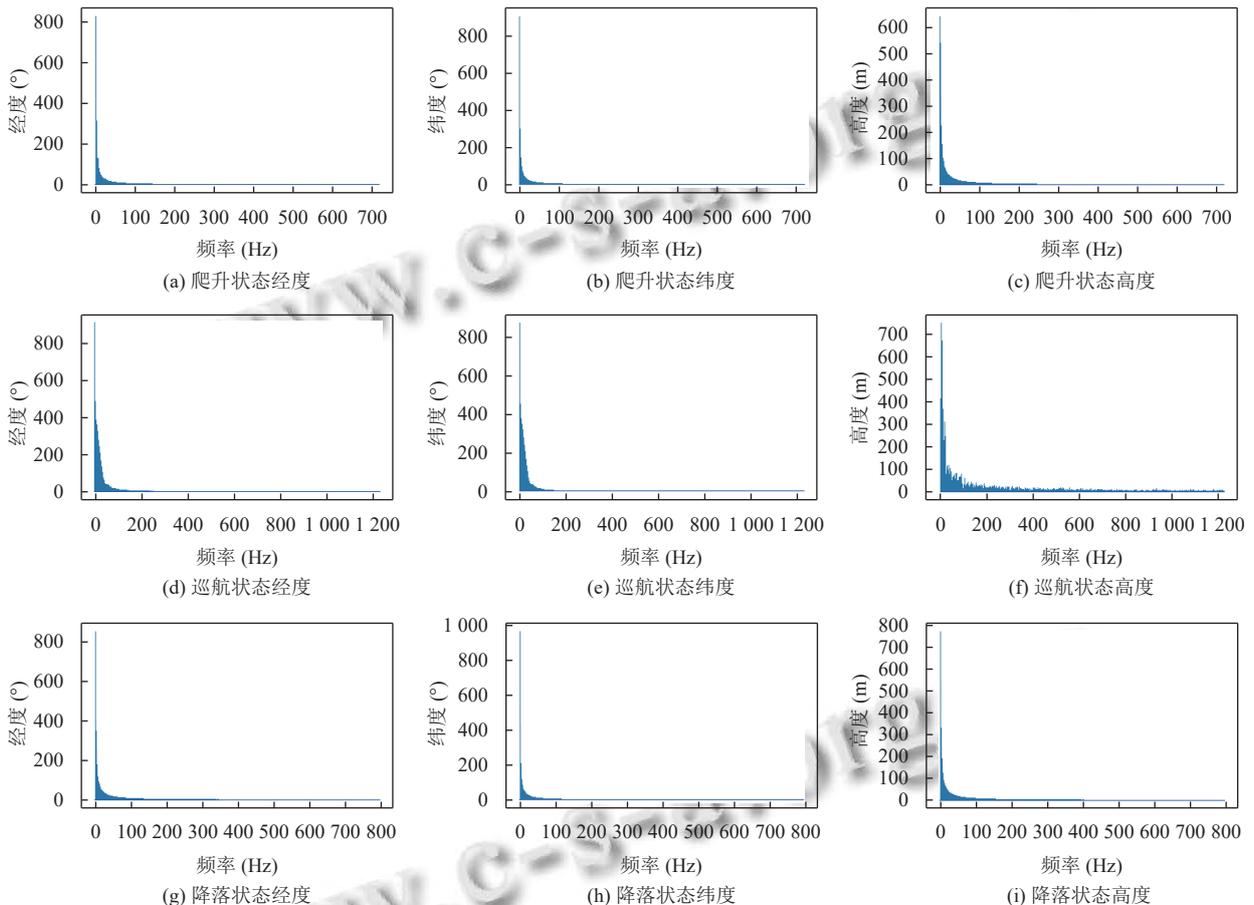


图6 3种飞行状态下轨迹数据的频域可视化

3 实验

3.1 数据集

所使用的数据集是通过相关设备来接收附近 200 km 空域内民航飞机发送的 ADS-B 广播报文, 并对其解码得到经度、纬度、高度这 3 个轨迹信息. 为了得到能输入到飞行轨迹预测网络模型的标准数据, 删除异常值和时间上的重复值; 实际收到的原始轨迹数据由于信号遮挡等原因而出现缺失值用三次样条插值法补齐; 属性变量具有不同的量纲和量纲单位, 直接使用进行模型计算会因变量的量纲不同而对模型输

出造成影响, 故使用 z-score 标准化方法对数据进行去量纲处理, 最终得到可以输入到轨迹预测网络模型的标准数据^[7].

3.2 评价指标

为了评估确定性结果, 使用均方根误差 (root mean square error, $RMSE$) 和平均绝对误差 (mean absolute error, MAE). MAE 是预测值与真实值之间绝对误差的平均值, $RMSE$ 是预测值和真实值之间的平方误差的平方根. 两者在飞行轨迹预测问题中都有广泛的应用, 其定义如式 (9)、式 (10) 所示.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (9)$$

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

其中, y_i 和 \hat{y}_i 分别表示在 t 时刻的真实值和预测值, n 表示预测点数. $RMSE$ 与 MAE 的值越小, 说明预测轨迹与真实轨迹之间的误差越小, 预测结果越精确.

3.3 实验结果与分析

3.3.1 参数设置

飞行轨迹预测指在给定飞行器当前或历史运动轨迹的情况下, 对其未来位置、速度、方向等状态信息进行预测的任务. 本文的输入序列长度为 6, 预测长度为 1, 即将飞行轨迹的前 6 个点作为输入样本来预测下一个轨迹点. 每两个轨迹点间的时间间隔为 1 s. 数据集样本的 70% 被划分为训练集, 20% 为测试集, 10% 为验证集来验证和调整模型. 飞行轨迹预测模型的实验在 Windows 环境下, 使用 Python 编程语言在 PyTorch 框架中实现, 超参数的设置为 $d_{ff}=128$, $d_{model}=128$, $n_{heads}=4$.

3.3.2 对比实验

为了验证提出的飞行轨迹预测模型的有效性, 将其与多个现有模型进行了对比. 不同飞行状态下的预测任务结果汇总于表 1 中, 该表详细列出了各个模型在爬升、巡航和降落 3 个关键飞行阶段的预测性能. 根据表中的数据, 本文提出的 SDFE-FPM 在指标上相对于次优模型, 在 3 种不同的飞行状态下分别实现了

4.1%、3.0% 和 5.7% 的改进率; 而在 $RMSE$ 指标下, 相应的改进率则分别为 5.6%、1.1% 和 5.0%. 这表明本文所提出的模型在处理不同飞行状态下的轨迹预测方面具有更高的准确性和鲁棒性.

表 1 不同飞行状态下的轨迹预测任务对比实验

| Model | 爬升 | | 巡航 | | 降落 | |
|--------------|------|-------|------|------|------|-------|
| | MAE | RMSE | MAE | RMSE | MAE | RMSE |
| Transformer | 6.27 | 12.94 | 0.21 | 1.02 | 1.02 | 2.21 |
| Flashformer | 5.82 | 11.84 | 0.28 | 1.29 | 1.04 | 2.14 |
| Flowformer | 5.34 | 10.93 | 0.27 | 1.24 | 1.31 | 2.71 |
| Crossformer | 1.31 | 2.69 | 0.19 | 0.96 | 0.89 | 1.80 |
| Pyraformer | 2.13 | 4.81 | 0.20 | 1.04 | 1.32 | 2.72 |
| Reformer | 1.30 | 2.70 | 0.16 | 0.90 | 1.35 | 2.76 |
| DLinear | 4.02 | 8.05 | 0.24 | 1.06 | 6.01 | 10.76 |
| TimesNet | 1.51 | 3.19 | 0.16 | 0.91 | 1.45 | 3.07 |
| PatchTST | 1.20 | 2.66 | 0.21 | 1.02 | 0.89 | 1.84 |
| iTransformer | 1.28 | 2.64 | 0.16 | 0.90 | 0.87 | 1.82 |
| SDFE-FPM | 1.15 | 2.46 | 0.15 | 0.89 | 0.82 | 1.71 |

图 7 为频域增强通道注意力机制热图. 图 7 中颜色越深 (接近红色) 表示注意力权重越高, 说明对应的通道和频率特征在当前飞行状态下的重要性更大. 在爬升和降落状态下, 特定频率通道的高注意力权重表明模型优先聚焦于瞬时动态特征, 这些特征对飞行状态的快速识别和轨迹预测至关重要; 而巡航阶段特征的均匀分布则体现了模型对稳定飞行状态下参数的微小波动具有持续敏感性. 这种差异化的权重分配机制反映了注意力模块对飞行状态依赖性的自适应建模能力, 既保证了非稳态阶段的关键特征强化, 又维持了稳态阶段的全局特征平衡, 从而在时空双重维度上优化了轨迹预测的鲁棒性与动态适应性.

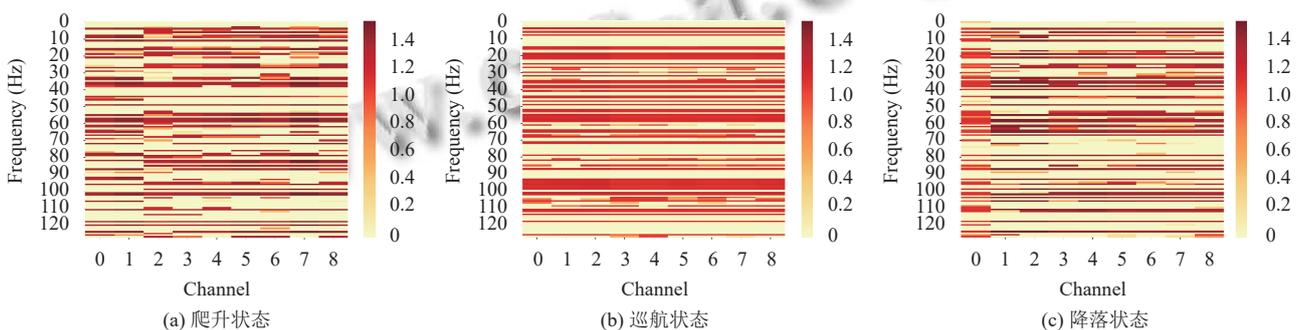


图 7 3 种飞行状态下频域增强通道注意力机制热图

如图 8 所示, 红色为真实轨迹, 蓝色为预测轨迹. 在爬升和降落阶段, 飞行器高度快速变化, 预测轨迹都能紧密跟随真实轨迹的变化, 显示了模型的准确性和稳定性. 尽管在某些点有轻微偏差, 整体表现依旧出色. 巡航阶段, 飞行器高度在 9748–9799 m 间波

动, 导致轨迹图出现不连续性或“跳变”. 虽然存在一些小预测偏差, 但总体上预测轨迹与真实轨迹仍保持较高接近度, 表明本文所提 SDFE-FPM 在不同飞行状态下均能有效预测飞行轨迹, 为飞行安全提供有力支持.

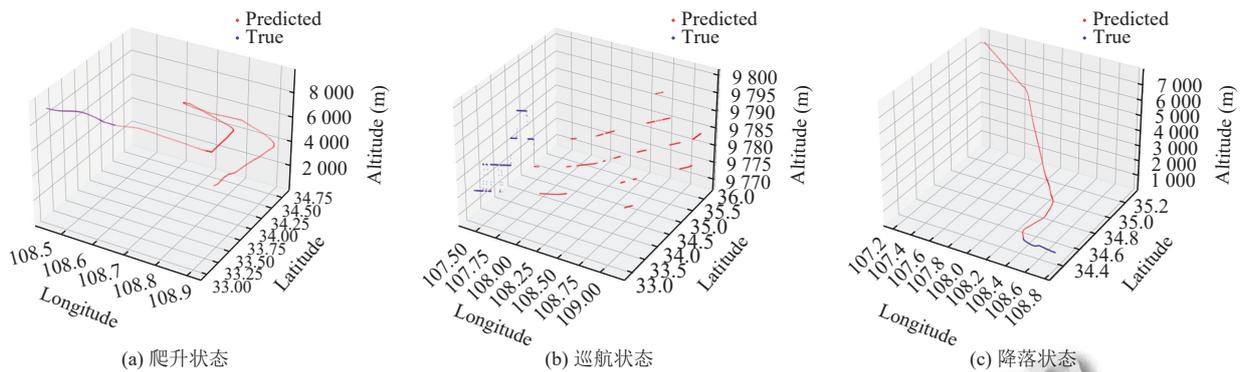


图8 3种飞行状态的轨迹预测结果可视化

3.3.3 消融实验

为系统分析各模块对网络模型性能的具体影响,本文选取以 TrmBlock 块为核心组件的 iTransformer 模型作为基准模型,在爬升、巡航和降落3种飞行状态下开展轨迹预测任务的消融实验.实验中重点关注 FECAM 模块与 TCN 网络中的因果膨胀卷积两个变量的影响机制.消融实验结果汇总于表2.

表2 3种飞行状态下的轨迹预测任务消融实验

| Model | 爬升 | | 巡航 | | 降落 | |
|--------------------|------|------|------|------|------|------|
| | MAE | RMSE | MAE | RMSE | MAE | RMSE |
| iTransformer | 1.28 | 2.64 | 0.16 | 0.90 | 0.87 | 1.82 |
| iTransformer+FECAM | 1.17 | 2.47 | 0.15 | 0.90 | 0.86 | 1.81 |
| iTransformer+TCN | 1.25 | 2.57 | 0.16 | 0.89 | 0.82 | 1.77 |
| SDFE-FPM | 1.15 | 2.46 | 0.15 | 0.89 | 0.82 | 1.71 |

表2中,因果膨胀卷积与 TrmBlock 块在 SDFEM 架构中的协同作用对于多尺度时序特征提取具有关键意义.具体而言,通过级联式因果膨胀卷积设计,模型能够在严格遵循时间序列单向性约束的前提下,以不同膨胀率实现局部瞬时特征与中长期依赖关系的分层提取.经特征增强后的时序表示随后输入 TrmBlock 模块,通过自注意力机制动态评估不同变量在同一时刻的重要性权重,从而强化关键特征对飞行状态预测的贡献度.实验数据显示,引入 TCN 网络中的因果膨胀卷积后,整体预测误差显著降低,进一步验证了其在多尺度时序建模中的有效性.

另一方面, FECAM 模块通过细粒度通道增强注意力机制显著提升了多变量交互关系的建模能力.该模块首先利用 DCT 将输入特征映射至频域空间,通过频率选择性增强策略突出关键通道的贡献.例如,在降落阶段,高度、速度与姿态角等变量间的强耦合关系对安全着陆具有决定性意义, FECAM 通过自适应通道权

重分配机制,能够动态放大这些关键变量的特征响应.实验结果表明, FECAM 模块在全局特征优化方面展现出显著优势,并有效实现了局部特征与全局模式的协同增强.

相较于单一模块的改进效果,本文提出的 SDFE-FPM 框架在所有飞行阶段中均展现出最优的预测性能.这一结果不仅验证了 SDFEM 与 FECAM 在设计合理性和计算精度上的优势,更揭示了二者在时空特征建模中的互补性.

4 结论

本文提出了 SDFE-FPM.该方法首先采用因果膨胀卷积结构,以有效捕捉飞行轨迹数据中复杂的局部时间依赖关系,随后引入 TrmBlock 模块,进一步提升模型对多变量之间非线性耦合关系的建模能力,强化其全局交互特征的学习效果.此外,数据频域特征的有效提取与表达增强,从而提升整体预测性能.实验结果表明,所提方法在飞行器爬升、巡航和降落这3个关键飞行阶段的轨迹预测任务中均表现出优异的预测精度与稳定性.相较于现有主流方法,在多个评估指标上均取得了显著提升,验证了所提模型在复杂飞行场景下的有效性与鲁棒性.

参考文献

- 1 程程. 基于机器学习的飞行器避撞和轨迹预测技术研究 [硕士学位论文]. 南京: 南京邮电大学, 2022.
- 2 张硕. 机场终端区航空器态势感知系统建模与仿真研究 [硕士学位论文]. 天津: 中国民航大学, 2023.
- 3 王浩杰. 民用航空器运行大数据轨迹预测算法研究 [硕士学位论文]. 广州: 广州大学, 2024.
- 4 Ayhan S, Samet H. Aircraft trajectory prediction made easy with predictive analytics. Proceedings of the 22nd ACM

- SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco: Association for Computing Machinery, 2016. 21–30.
- 5 Zhou ZJ, Chen JL, Shen BB, *et al.* A trajectory prediction method based on aircraft motion model and grey theory. Proceedings of the 2016 IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC). Xi'an: IEEE, 2016. 1523–1527.
- 6 田杉. 基于神经网络的4D航迹预测方法[硕士学位论文]. 天津: 中国民航大学, 2020.
- 7 严皓. 基于改进LSTM的终端区进港航班4D航迹预测研究[硕士学位论文]. 广汉: 中国民用航空飞行学院, 2023.
- 8 翟文鹏, 宋一峤, 张兆宁. 基于Transformer-GRU网络的4D航迹预测. 重庆交通大学学报(自然科学版), 2024, 43(6): 94–101.
- 9 Dong ZJ, Fan BY, Li F, *et al.* TCN-informer-based flight trajectory prediction for aircraft in the approach phase. Sustainability, 2023, 15(23): 16344. [doi: [10.3390/su152316344](https://doi.org/10.3390/su152316344)]
- 10 Liu Y, Hu TG, Zhang HR, *et al.* iTransformer: Inverted transformers are effective for time series forecasting. arXiv: 2310.06625, 2023.
- 11 Ren YH, Xiong QL, Qu C, *et al.* MS-GATformer: Multi-scale hybrid prediction based on GAT-iTransformer. Proceedings of the 2024 China Automation Congress (CAC). Qingdao: IEEE, 2024. 1427–1431.
- 12 Xie RY, Liang C, Zheng XP, *et al.* Short-term PV cluster power prediction based on fuzzy C-means and iTransformer-TCN. Proceedings of the 16th IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC). Nanjing: IEEE, 2024. 1–5.
- 13 Zhou T, Ma ZQ, Wen QS, *et al.* FEDformer: Frequency enhanced decomposed Transformer for long-term series forecasting. Proceedings of the 39th International Conference on Machine Learning. Baltimore: PMLR, 2022. 27268–27286.
- 14 施黄凯, 王彩玲, 刘华军. 基于时频域信息融合和多尺度对抗的轨迹预测. 计算机系统应用, 2023, 32(12): 268–275. [doi: [10.15888/j.cnki.csa.009324](https://doi.org/10.15888/j.cnki.csa.009324)]
- 15 Jha A, Dorkar Q, Biswas A, *et al.* iTransformer network based approach for accurate remaining useful life prediction in lithium-ion batteries. Proceedings of the 2024 IEEE Transportation Electrification Conference and Expo (ITEC). Chicago: IEEE, 2024. 1–8.
- 16 Dai ATN, Vo Thi TT, Nguyen TB. Applying iTransformer for Saigon River water level forecasting. Proceedings of the 2024 International Conference on Advanced Technologies for Communications (ATC). Ho Chi Minh City: IEEE, 2024. 556–560.
- 17 Zuo KW. Integrated forecasting models based on LSTM and TCN for short-term electricity load forecasting. Proceedings of the 9th International Conference on Electrical Engineering, Control and Robotics (EECR). Wuhan: IEEE, 2023. 207–211.
- 18 Bai SJ, Kolter JZ, Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. arXiv:1803.01271, 2018.
- 19 丁伟杰. 基于深度混合神经网络的航迹预测关键算法研究[硕士学位论文]. 广汉: 中国民用航空飞行学院, 2023.
- 20 Ye L, Li YL, Pei M, *et al.* A novel integrated method for short-term wind power forecasting based on fluctuation clustering and history matching. Applied Energy, 2022, 327: 120131. [doi: [10.1016/j.apenergy.2022.120131](https://doi.org/10.1016/j.apenergy.2022.120131)]
- 21 Peng HQ, Sun H, Luo SX, *et al.* Diffusion-based conditional wind power forecasting via channel attention. IET Renewable Power Generation, 2024, 18(3): 306–320. [doi: [10.1049/rpg2.12825](https://doi.org/10.1049/rpg2.12825)]
- 22 李明阳, 鲁之君, 曹东晶, 等. 一种基于Transformer编码器与LSTM的飞机轨迹预测方法. 航天返回与遥感, 2024, 45(2): 163–176. [doi: [10.3969/j.issn.1009-8518.2024.02.016](https://doi.org/10.3969/j.issn.1009-8518.2024.02.016)]
- 23 Zhuo YA, Hao ZM, Mao YF, *et al.* Bearing remaining useful life prediction based on TCN-Transformer model. Proceedings of the 2023 CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes (SAFEPROCESS). Yibin: IEEE, 2023. 1–6.
- 24 Zhang J, Chen Y, Wang R, *et al.* Enhancing civil aviation day-to-day passenger and cargo volume forecasting with iTransformer: Multimodal integration and predictive accuracy. Proceedings of the 6th IEEE International Conference on Civil Aviation Safety and Information Technology (ICCASIT). Hangzhou: IEEE, 2024. 543–548.
- 25 Jiang MW, Zeng PY, Wang K, *et al.* FECAM: Frequency enhanced channel attention mechanism for time series forecasting. Advanced Engineering Informatics, 2023, 58: 102158. [doi: [10.1016/j.aei.2023.102158](https://doi.org/10.1016/j.aei.2023.102158)]
- 26 Hu J, Shen L, Sun G, *et al.* Squeeze-and-excitation networks. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 7132–7141.

(校对责编: 李慧鑫)