

基于 Transformer 模型的四旋翼无人机时空协同航迹预测方法设计

欧 洋¹, 漆雪莲², 胡清月¹

(1. 中国电子科技集团公司 第 10 研究所, 成都 610036;

2. 四川省交通运输集团有限责任公司, 成都 610000)

摘要: 无人机在执行任务时面临的飞行环境复杂多变, 为了减少事故的风险, 并在飞行时对异常情况进行预测和响应, 研究一种基于 Transformer 模型的四旋翼无人机时空协同航迹预测方法; 采集四旋翼无人机原始航迹, 实施异常点剔除和缺失点插值处理, 以优化和清理原始航迹数据, 便于后续的航迹预测; 使用卷积神经网络实施特征进行数据提取, 通过编码和解码过程获取学习数据低维, 结合深度学习和表示学习方法完成数据降维; 基于 Transformer 模型实现无人机时空协同航迹的精准预测, 通过数据异常点剔除与插值补缺, 对采集的四旋翼无人机原始航迹数据实施预处理, 提高数据的质量和完整性; 实验测试结果表明, 设计方法的预测结果虽然相对于真实的坐标点稍有偏差, 然而整体结果在可接受范围内, 验证集所有数据的均方误差在数据条数为 300 时仅为 0.32 m, 拟合优度指标测试结果最接近 1, 具有良好的航迹预测能力; 该方法可以更好地优化无人机的航迹规划, 实现多无人机之间的时空协同航迹规划, 避免碰撞和冲突, 并优化飞行效率。

关键词: Transformer 模型; 四旋翼无人机; 表示学习; 时空协同航迹预测

Design of Spatiotemporal Collaborative Trajectory Prediction Method for Quadcopter UAVs Based on Transformer Model

OU Yang¹, QI Xuelian², HU Qingyue¹

(1. The 10th Institute of China Electronics Technology Group Corporation, Chengdu 610036, China;

2. Sichuan Transportation Group Co., Ltd., Chengdu 610000, China)

Abstract: In order to reduce the risk of accidents and predict and respond to abnormal situations in the complex and changeable flight environments faced by unmanned aerial vehicles (UAVs) during mission execution, a spatiotemporal collaborative trajectory prediction method based on Transformer model for quadcopter UAVs is studied. Collect the original trajectory of the quadcopter drone, implement the outlier removal and missing point interpolation processing to optimize and clean up the original trajectory data for subsequent trajectory prediction. Convolutional neural networks are used to conduct the feature extraction, the low dimensional learning data are obtained through encoding and decoding processes, and deep learning and representation learning methods are combined to complete the data dimensionality reduction. Based on the Transformer model, the UAV spatiotemporal cooperative trajectory is precisely predicted. By removing the outliers and interpolation, the collected raw trajectory data of quadcopter UAVs is preprocessed to improve the quality and completeness of the data. The experimental test results show that although the prediction results of the design method have a slight deviation from the actual coordinate points, the overall results are within an acceptable range. The mean square error of all data in the validation set is only 0.32 m when the number of data is 300, and the goodness of fit index is closest to 1, indicating its good trajectory prediction ability. This method can better optimize the trajectory planning of drones, achieve spatiotemporal collaborative trajectory planning among multiple drones, avoid collisions and conflicts, and optimize flight efficiency.

Keywords: Transformer model; quadcopter UAV; represent learning; spatiotemporal collaborative trajectory prediction

0 引言

四旋翼无人机由于其灵活的飞行能力和强大的负载能力, 成为无人机领域中的重要一员。在复杂的战场环境和未知的飞行环境中, 四旋翼无人机的航迹预测对于任务的

成功执行具有举足轻重的意义^[1]。在军事应用方面, 精确的航迹预测能够帮助无人机更好地执行侦察、攻击等任务; 对于民用应用方面, 如灾害救援、环境监测等, 能够准确的航迹预测能提高任务的效率和成功率。但在实际应用中, 四旋翼无人机通常面临着复杂的飞行环境和多种不确定因

收稿日期: 2023-11-30; 修回日期: 2024-01-11。

作者简介: 欧 洋(1985-), 男, 硕士, 工程师。

通讯作者: 胡清月(1998-), 女, 硕士, 工程师。

引用格式: 欧 洋, 漆雪莲, 胡清月. 基于 Transformer 模型的四旋翼无人机时空协同航迹预测方法设计[J]. 计算机测量与控制, 2024, 32(6): 58-64, 70.

素, 如气流、风力、电池电量等, 这些因素会对航迹预测产生影响^[2]。此外, 对于执行复杂任务的四旋翼无人机, 其航迹规划需要考虑多种因素, 如任务目标、安全限制等, 这些因素使得航迹预测更具挑战性。无人机的时空协同能力对于实现多无人机系统的安全、高效运行至关重要。最佳航迹规划和资源分配可以提高协同效率, 并避免碰撞和冲突。飞行轨迹预测可以帮助无人机选择最佳的路径和航线, 以达到特定的目标。通过分析预测的飞行轨迹, 可以识别出最短路径、最优速度以及最有效的航线。这将最大程度地减少飞行时间和能耗, 并提高整体的飞行效率。四旋翼无人机航迹预测方法的研究仍处于不断发展和深入的阶段。现有的研究主要集中在飞行动力学建模、航迹预测算法设计和优化等方面, 并结合了深度学习等先进技术。然而, 如何实现更加准确、鲁棒地预测方法仍然是一个挑战性的问题, 需要进一步地研究和探索。

文献 [3] 中提出了一种四旋翼无人机在线规避航迹规划方法, 仿真结果表明, 该方法运算效率较高、成功率较高、平滑度较好, 可以在快速飞行过程及未知环境中自动避障, 适合用于四旋翼无人机的在线规避航迹规划。文献 [4] 中提出基于改进人工势场法的四旋翼无人机航迹规划算法, 并证明了该算法的优越性和有效性。文献 [5] 中则提出了一种基于 LSTM 的四旋翼无人机轨迹预测方法, 取得了良好的预测结果。文献 [6] 中提出剪切变换、数值归一化、shuffle 以及水平和垂直翻转操作等增强方法, 使模型更具泛化能力。以上方法需要实施复杂的计算和优化, 增加了计算时间和计算成本, 难以满足实时性要求, 同时预测误差偏大。

为克服以上问题, 更好地满足实际应用需求, 需要研究更加先进、高效、准确的无人机轨迹预测方法。现设计一种基于 Transformer 模型的四旋翼无人机时空协同航迹预测方法。采集四旋翼无人机原始航迹, 对航迹进行异常点剔除和缺失点插值, 从而提高数据的完整性。结合深度学习和表示学习, 设计四旋翼无人机航迹预测的数据降维方法, 基于 Transformer 模型的时空协同航迹预测通过位置编码, 时间编码和自注意力机制实现特征交互和解码, 实现高效准确的航迹预测。精确的飞行轨迹预测, 可以更好地优化无人机的航迹规划。

1 无人机航迹数据处理方法

采集四旋翼无人机原始航迹数据, 优化和清理原始航迹数据, 以便后续的航迹预测, 通过异常点剔除与插值补缺方法填补数据中的缺失值, 从而提高数据的完整性。结合深度学习和表示学习, 设计出四旋翼无人机航迹预测的数据降维方法。

1.1 原始航迹数据异常点剔除与插值补缺方法

四旋翼无人机原始航迹的采集步骤具体如下:

1) 确定航迹采集的规则和参数: 首先需要确定航迹采集的基本规则和参数, 如航迹点的位置精度、航迹点的间

隔时间、最大航迹点数量等^[7]。这些规则和参数将直接影响到最终的航迹数据质量和数量。

2) 选择四旋翼无人机后安装高精度的传感器: 在无人机上安装高精度传感器, 用于采集航迹数据。具体包括 GPS、加速度计、陀螺仪, 以及高清摄像头和激光雷达等, 在采集航迹的同时获取更多的环境信息。

3) 设计飞行路径和任务: 根据采集目的和要求, 设计合理的飞行路径和任务。可以采用随机搜索模式、扫描模式或预设路径模式等, 以增加无人机在航迹采集过程中的变化性和多样性。

4) 实现数据采集: 通过编程或使用无人机控制软件, 实现采集数据的实时传输和初步处理, 以得到准确的航迹数据^[8]。

5) 实施验证和优化: 通过调整无人机的飞行速度、改变传感器的采样频率等方式实施优化。

6) 考虑环境和气候因素: 在无人机上安装风力、温度、湿度传感器, 用于实时监测环境和气候条件, 以便在必要时对飞行路径和参数实施调整。

7) 记录和整理数据: 最后, 需要对采集到的原始航迹数据实施记录和整理。使用数据库来保存这些数据, 并按照指定的格式实施整理和组织。

航迹预处理是一个关键步骤, 旨在优化和清理原始航迹数据, 以便后续的航迹预测^[9]。以下是航迹预处理中异常点剔除和缺失点插值的详细过程:

1) 异常点剔除: 异常点是指数据集中与大多数数据明显不同的数据点, 它们可能由于各种原因如传感器故障、数据传输错误等产生。在航迹数据中, 异常点可能会导致模型预测精度下降, 因此需要剔除。

异常点剔除的过程如下:

(1) 计算航迹数据的均值和标准差。均值可以反映大部分数据点的集中趋势, 而标准差则可以反映数据点的离散程度;

(2) 根据均方根法则, 设定一个阈值, 通常为均值加减 3 倍标准差。超出这个阈值的点被认为是异常点;

(3) 剔除异常点。对于超出阈值的航迹点, 将其从数据集中剔除。异常点剔除公式如下:

$$a = m \pm 3 \times \bar{a} \quad (1)$$

式中, m 表示航迹数据的均值, 3 是根据均方根法则设定的阈值, \bar{a} 表示标准差。

2) 缺失点插值: 由于各种原因如传感器故障、数据丢失等, 航迹数据中可能会出现缺失点^[10]。为了保持航迹的连续性和完整性, 需要对缺失点实施插值处理, 插值方法是一种通过在已知数据点之间进行推断来估计未知数据点的技术。在数学和计算机科学中广泛应用, 常用于数据处理、图像处理、信号处理等领域。

缺失点插值的过程如下:

(1) 寻找缺失点。遍历航迹数据, 找到值为 NaN (Not

a Number) 的航迹点。

(2) 使用插值方法填充缺失点。根据实际需求和数据的特性, 选择合适的插值方法。对于四旋翼无人机航迹数据, 如果航迹点之间的时间间隔是等长的, 那么线性插值是一个合适的选择, 对于时间序列数据, 时间插值方法是常用的改进方法。线性插值假设数据点之间的变化是线性的, 可通过根据时间间隔进行插值来预测中间时间点的数值, 且线性插值假设航迹点的移动速度是恒定的。如果是更复杂的移动模式, 需要使用多项式插值或样条插值^[11]。

对于线性插值, 可以通过拟合一条直线来连接已知的航迹点。在 Python 中, 使用 Numpy 库的 polyfit () 函数来拟合直线, 然后使用 poly1d () 函数来创建一个可以用于计算的函数。最后, 使用这个函数在缺失的位置计算出新的航迹点。

对于多项式插值和样条插值, 需要使用 Scipy 库的相关函数。其中, scipy.interpolate.BarycentricInterpolator () 可以用于创建基于加权的多项式插值。

将计算出的新航迹点替换原来的 NaN 值。在 Pandas 库中, 使用 fillna () 函数来完成这个操作。其中, df.fillna (new_value) 会用 new_value 替换所有 NaN 值。

3) 对插值后的航迹数据与原始数据实施合并。在 Pandas 库中, 可以使用 concat () 或 merge () 函数来完成这个操作。其中, pd.concat ([df, new_data]) 能够将新的数据与原始数据合并。

插值方法可以填补数据中的缺失值, 从而提高数据的完整性。在 Transformer 模型的训练中, 缺失值可能导致特征信息的损失和误导, 影响模型的性能。通过使用插值方法, 可以合理地估计缺失值, 并补全数据集, 提供更全面的特征信息给 Transformer 模型。

1.2 基于深度学习和表示学习的数据降维方法

四旋翼无人机航迹预测是一个复杂的问题, 需要处理大量的数据, 做出准确预测。采用的处理方法为表示学习方法, 该方法是一种能够有效地处理大规模数据并学习其表示的方法。结合深度学习和表示学习^[12]设计四旋翼无人机航迹预测的数据降维方法。

1) 标准化处理。四旋翼无人机航迹预测的数据降维方法旨在减少计算复杂度、消除冗余信息、改善模型泛化能力以及提取关键特征。这些方法可以提高预测模型的效率和性能, 为无人机航迹预测问题提供更合理和可靠的解决方案。数据预处理是对原始数据进行清洗、转换和集成等操作, 以提高数据质量和模型性能。在数据预处理阶段, 可以应用数据降维方法来减少特征的数量, 从而简化数据集并提高处理效率。对预处理后的原始航迹数据实施标准化处理。使用 z-score 实施标准化处理, 将数据的尺度归一化到同一尺度, 处理后的航迹数据设为 x 。

2) 特征提取。使用卷积神经网络实施特征提取。CNN 可以有效地处理图像和形状数据, 适合处理四旋翼无人机

航迹数据。具体公式为:

$$\begin{cases} f = activation(n_1 \times x_{train} + d_1) \\ f_pool = maxpool(af) \\ f_2 = activation(n_2 \times f_pool + d_2) \\ f_2_pool = maxpool(af_2) \\ f_3 = activation(n_3 \times f_2_pool + d_3) \\ f_3_pool = maxpool(af_3) \\ \vdots \\ f_m = activation(n_m \times f_{m-1_pool} + d_m) \\ f_m_pool = maxpool(af_m) \end{cases} \quad (2)$$

式中, $n_1, d_1, n_2, d_2, n_3, d_3$ 一直到 n_m, d_m 为网络参数; $activation$ 表示激活函数; $maxpool$ 表示最大池化操作; a 表示异常点剔除后数值; $f, f_pool, f_2, f_2_pool, f_3, f_3_pool$ 一直到 f_m, f_m_pool 是指各层提取出数据的特征^[13]。CNN 卷积神经网络通过多层卷积、激活函数和池化操作进行特征提取, 并最终通过全连接层进行航迹预测, 流程如图 1 所示。

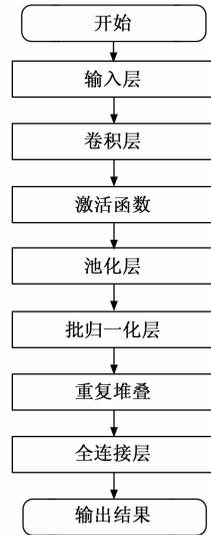


图 1 CNN 卷积神经网络流程图

在选择卷积神经网络的层数和滤波器数量时, 需要考虑可用的计算资源和实时性要求。过深的网络和较大的滤波器数量可能导致计算和存储开销过大, 在实时场景中难以满足要求。可以根据实际情况选择适当的层数和滤波器数量, 以平衡模型性能和实时性。

3) 表示学习。表示学习中的自编码器是一种无监督的神经网络模型, 通过编码和解码过程获取学习数据的低维表示为:

$$\begin{cases} V = af_3 \zeta(f_n) \\ x_r = \psi(V) \end{cases} \quad (3)$$

式中, 自编码器的编码器 ζ 和解码器 ψ 为深度神经网络; f_n 是指最终的数据特征表示; V 指的是编码结果; x_r 是指数据降维结果^[14]。通过优化目标函数, 从而获取数据的低维

表示。

2 基于 Transformer 模型的时空协同航迹预测方法

通过数据异常点剔除与插值补缺, 对采集的四旋翼无人机原始航迹数据实施预处理, 可以提高数据的质量和完整性, 保留重要的数据信息。在此基础之上, 实施数据降维处理, 可以选择性地保留数据中最重要的特征和信息, 减少冗余信息的干扰, 突出数据中的关键结构, 提高航迹预测精度。

传统的循环神经网络在处理长程依赖时容易出现梯度消失或梯度爆炸的问题。而 Transformer 模型通过自注意力机制, 能够在全局范围内建模序列中任意元素之间的依赖关系, 更好地捕捉到长程依赖。这使得 Transformer 在许多任务中比传统的循环神经网络模型表现更好。但为了保留输入序列的位置信息, Transformer 模型使用位置编码来表示序列中各个元素的位置。位置编码的计算复杂度与序列长度呈线性关系, 在较长序列和更大模型规模的情况下增加计算开销。

基于 Transformer 模型实现四旋翼无人机时空协同航迹预测。模型包含 6 个编码器与 6 个解码器。编码器结构完全相同, 具有独立参数并可于训练中更新, 译码器结构也完全相同, 仅参数不同。6 个编码器串联, 前一个编码器的输出是后一个编码器的输入, 四旋翼无人机航迹矩阵经表示学习后输入至第一个编码器中, 最后一个编码器的输出称为注意力信息 $Attn$, 是 6 个译码器的输入^[15]。6 个译码器串联, 前一个译码器的输出是后一个译码器的输入, 不同于编码器, 译码器的输入有两个, 一个是待预测时间实施时间嵌入以后的时间特征矩阵, 而另一个输入则是空间特征矩阵即注意力信息 $Attn$ 。基于 Transformer 模型的时空协同航迹预测通过位置编码, 时间编码和自注意力机制实现特征交互和解码, 实现高效准确的航迹预测, 如图 2 所示。

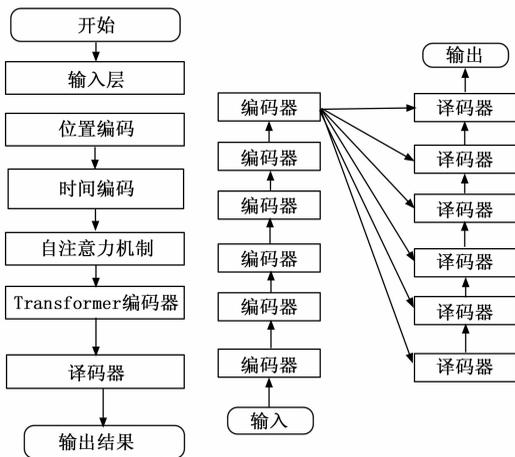


图 2 Transformer 模型的时空协同航迹预测的流程

整个模型的运行具体流程如下:

1) 四旋翼无人机的空间航迹经过表示学习后可得到一个特征矩阵—航迹特征矩阵 c , 将其送入第一个编码器。就这样, c 以相同的数据尺度不断通过 6 个编码器, 第六个编码器的输出即为空间特征矩阵即注意力信息 $Attn$, 具体如下所示:

$$Attn = x_r F_\chi(J_{pn}; R_E, M_E, \epsilon_E, j_E) \quad (4)$$

式中, F_χ 为指编码函数, J_{pn} 为空间特征数值, R_E 为编码器的层数, ϵ_E 为编码器激活函数, j_E 为编码器偏差参数, M_E 为编码器网络的对应权重^[16]参数。

2) 在需要预测无人机位置的特定时刻 (待预测时间), 利用预测时间嵌入获得时间特征矩阵 d_c 。将 d_c 与注意力信息当作输入不断通过 6 个译码器。第六个译码器的输出即为四旋翼无人机的时空协同航迹预测结果, 用 q_{uv} 来表示。 q_{uv} 的表达式具体如下:

$$q_{uv} = \iota(R_{hd}; \chi, F_\chi, R_\chi) \quad (5)$$

式中, ι 为 Transformer 模型架构, R_{hd} 为观测序列, 即前半段飞机航迹, χ 为时间嵌入模块, R_χ 为译码器^[17]。其中时间嵌入模块 χ 的表达式具体如下:

$$\chi = q_{uv} \delta(R_{hd}; M_i, j_i) \quad (6)$$

式中, δ 为时间嵌入函数, M_i 为时间嵌入模块的权值参数, j_i 为时间嵌入模块的偏重参数。译码器 R_χ 的表达式具体如下:

$$R_\chi = \chi(Attn, d_c; R_d, M_d, \epsilon_d, j_d) \quad (7)$$

式中, R_d 为译码器的层数, M_d 为解码器网络对应的权重参数, j_d 为译码器偏差参数, ϵ_d 为译码器激活函数。将该模型的损失函数定义为:

$$S = R_\chi \min_{H, j, d} \sum_{l=1}^w (x_l - q_{red_l})^2 \quad (8)$$

式中, q_{red_l} 为第 l 个预测结果, H 为预测模型最适合的网络权值参数, 由 M_E, M_i, M_d 构成, j 为预测模型的偏差函数, 由 j_E, j_i, j_d 构成, W 为指训练次数, x_l 为第 l 个反向传播最小化真实值^[18]。编码器共由 3 个模块组成: 前馈神经网络模块、层归一化与残差连接模块、多头自注意力模块。其中各编码层的输出特征维度与输入特征维度完全相同, 确保编码器能够多个串接, 从而增加 Transformer 模型神经网络的深度。

多头自注意力模块由 3 个线性层、一个缩放点积注意力层、一个合并层以及一个线性层构成。其中 3 个线性层中输入的分别为值特征 V 、键特征 K 、查询特征 Q 。 V, K, Q 是通过航迹特征矩阵 c 与不同的权值矩阵 M_V, M_K, M_Q 相乘获得的。通过不同的权值矩阵, 能够对航迹特征矩阵 c 实施不同的线性变换, 将 c 映射至不同子空间。

在缩放点击自注意力层中能够实现自注意力操作, 也就是矩阵 Q 到 $K-V$ 的映射, 其中 $K-V$ 是指 KEY 与 V 构成的矩阵对。

具体来说, 注意力操作可以分为 3 步:

首先需要计算 Q 和 K 之间的关联程度。这可以通过对 Q 和 K 实施点积运算来实现, 通过点积运算能够得到每个

航迹点与其余航迹点之间的关联程度数值。

接下来，通过归一化指数函数对关联程度数值实施计算，从而得到关联程度分数矩阵。在这个矩阵中，每个航迹点与其余航迹点之间的关联分数加起来和为 1。

最后，将当前位置与其他位置之间的关联程度分数以及其对应的键值 G 相乘并累加，以得到最终结果^[19]。可以用下式来表示自注意力预测的整体流程：

$$A_T(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Ssoftmax}\left(\frac{\mathbf{QK}}{\sqrt{c_k}}\right)\mathbf{V} \quad (9)$$

式中， c_k 指的是向量 \mathbf{Q} 的维度， $A_T(\mathbf{Q}, \mathbf{K}, \mathbf{V})$ 是指自注意力运算。缩放点击自注意力层为多头结构，每个头具有独立的权重参数，这有助于算法从不同方向挖掘特征。这种结构与卷积神经网络中的多个卷积核类似，可以提升模型的特征提取能力。通过这种方式，模型可以更有效地从输入数据中提取有用的特征，从而提升模型的性能。

合并层是对多个注意力头的结果实施合并，最终以一个线性层收尾。层归一化与残差连接模块能够实现前馈神经网络模块与多头自注意力模块的层归一化操作与残差连接操作。其中残差连接使得时空协同航迹预测模型能够更容易地实施训练，避免了网络深度增加时出现的网络退化问题。残差网络使得训练高层模型成为可能。层归一化处理是在特征维度上实施归一化，将特征转化为正态分布，从而将数据重新拉回到激活函数内的非饱和区域。这种方法可以加快训练速度，提高模型精度，并减缓梯度消失。层归一化与残差连接模块可以共同由下式来表达：

$$S - L - O = L_N[\alpha + S_{UB}(\alpha)] \quad (10)$$

式中， α 为输入， S_{UB} 为残差操作， L_N 为归一化操作。前馈神经网络模块包含激活函数与线性变换。前馈网络层在理论上能够逼近任意函数，使得预测模型能够找到最优的函数映射。实现应用 4 倍嵌入维度的大小来对特征实施扩维，实际扩展维度为 2 048，最后经过线性变换后还原至 512 维，从而保证输出与输入的尺度相同。在选择激活函数时，选用了 Bert 模型的 GELU 激活函数^[20]。与编码器的结构不同，译码器由预测时间嵌入模块、3 个层归一化与残差连接模块、一个前馈网络层和 2 个不同的注意力模块组成。其中时间特征矩阵会首先进入多头自注意力模块，该注意力模块带有掩模功能，是对于一个输入的关联，接着进入第二个注意力模块—多头注意力模块，该模块带有掩模功能，不会遮挡后面输入序列，其次该模块还增加了注意力信息并将该信息作为额外输入。时间特征矩阵每通过一次前馈网络层或注意力层，都会实施残差及层归一化处理。因此译码器与编码器之间的主要区别如下：与编码器的单个输入不同，译码器有两个输入，分别为待预测时间的高维嵌入与编码器输出的空间特征矩阵，其中空间特征矩阵是连接译码器与编码器的桥梁。以及译码器具备掩模功能，以避免模型训练过程中发生当预测当前航迹点位置时可能看到后续航迹点位置的情况。

各译码器的输出特征维度与输入特征维度是完全相同的，确保了多个译码器能够串接。此外，仅对生成时间特征矩阵的预测时间嵌入模块、多头自注意力模块和多头注意力模块实施介绍。这些模块是编码器与译码器的区别所在，而其余部分则与编码层完全相同。

预测时间嵌入模块为对待预测时间实施时间嵌入的模块，通过该模块能够获取时间特征矩阵。待预测时间是预测飞机后续每个时间点的精确位置时需要提供的信息，以秒为单位。模型默认每隔 T 秒预测一次四旋翼无人机精确位置，并将观测的最后一个无人机航迹点作为对比。因此，将待预测序列默认为如下式的时间间隔：

$$T' = T, 2T, 3T, \dots, nT \quad (11)$$

待预测时间也是时间间隔序列，借鉴处理自然语言时生成词特征向量的思路，将各时间间隔设为一个单词，采用先建立字典接着实施词嵌入的方式获得高维特征向量，其维度为 512 维，最终获得译码器的输入—时间特征矩阵。多头自注意力模块 (MASK) 和模型编码器中的多头自注意力模块类似，区别在于 MASK 模块有着特殊的 MASK 机制，下面介绍 MASK 机制。

当模型在训练时，译码器会一次性接收全部需要预测的四旋翼无人机航迹点。假设当前已经预测了前 5 个航迹点，现在需要预测第 6 个。如果模型能够看到全部输入的待预测航迹点，那么它可以直接找到第 6 个航迹点，即需要预测的答案。这相当于模型不必实施更新和优化，只需要从输入航迹点中找到答案。但遗憾的是，在预测阶段，模型一次只能输入一个飞机航迹点，因此这种“偷懒”行为无法发挥作用。为了防止模型在训练时提前看到后续需要预测的答案，采用了 MASK 机制来保证在预测每一个轨迹点时，只有当前位置及之前的能够被看到。MASK 机制是一个倒三角矩阵，长度和宽度均等于输入航迹点序列的长度。绿色部分表示不遮挡，黄色部分表示遮挡。每一个轨迹点及之前的均不遮挡，后面的则实施遮挡，从而确保模型无法预览到当前位置后续输入。MASK 机制在计算查询矩阵和键矩阵的点积结果后起作用。绿色位置的值不变，而黄色位置被遮挡位置的值变为一个无穷小的数，将其设置为 10^{-6} 。

编码器和译码器都配置了多头自注意力模块，但它们输入该模块的信息数量存在差异。编码器的多头自注意力模块仅接收航迹特征矩阵作为输入。然而，译码器则有两类输入，分别是时间特征矩阵和空间特征矩阵^[21]。在这个模块中，解码层利用了编码器输出的注意力信息，也就是存储的观测序列的特征和规律。这样使得解码层能够充分运用已经观测到的轨迹信息，更为精准地预测下一个轨迹点的位置。

$$A'_T(\mathbf{Q}', \mathbf{K}', \mathbf{V}') = S - L - O_{\max}\left(\frac{\mathbf{V}'\mathbf{Q}'\mathbf{K}'}{\sqrt{c_k}}\right)T' \quad (12)$$

就此完成四旋翼无人机时空协同航迹预测模型的设计。

3 算例验证

为验证基于 Transformer 模型的四旋翼无人机时空协同航迹预测方法展开测试, 通过对比的方法进而验证本文提出方法的预测效果、预测误差及预测能力。

3.1 实验数据采集

对于设计的基于 Transformer 模型的四旋翼无人机时空协同航迹预测方法, 利用其对某四旋翼无人机实施时空协同航迹预测, 以测试设计方法的预测性能。

首先采集实验四旋翼无人机的原始航迹,

确定航迹采集的规则和参数:

- 1) 位置精度: $\pm 0.5\text{ m}$;
- 2) 航迹点间隔时间: 50 ms ;
- 3) 最大航迹点数量: $2\ 000$ 个。

选择一款具有稳定飞行性能和较长续航时间的四旋翼无人机, 在无人机上安装高精度的 GPS、加速度计、陀螺仪, 以及高清摄像头和激光雷达等设备。采用了随机搜索模式, 使无人机在目标区域内的飞行路径具有较大的变化性和多样性。设定多个飞行高度和速度的变化后实施数据采集, 采集及处理后的部分数据如表 1 所示。

表 1 处理后的部分数据

无人机型号	飞行日期	时间	经度 / ($^{\circ}$)	纬度 / ($^{\circ}$)	高度 / m	速度 / (m/s)	方向
MACH4	2022-01-02	16:34:14	114.103	29.167	628	670	234.22
MACH4	2022-01-02	16:34:23	114.09	29.167	628	672	235.22
MACH4	2022-01-02	16:34:31	114.093	29.167	628	672	234.82
MACH4	2022-01-02	16:34:40	114.091	29.167	628	673	234.92

由于采集数据的时间间隔不同, 为了使时间序列的时间间隔相同, 以 10 s 为单位采用插值法实施数据采样。表 1 采样后的数据如表 2 所示, 每一行的间隔时间都相同, 其他特征按插值法求一个合适值填充。

表 2 采样后的数据

无人机型号	飞行日期	时间	经度 / ($^{\circ}$)	纬度 / ($^{\circ}$)	高度 / m	速度 / (m/s)	方向
MACH4	2022-01-02	16:34:10	114.087	29.167	628	670	234.22
MACH4	2022-01-02	16:34:20	114.085	29.168	628	672	235.22
MACH4	2022-01-02	16:34:30	114.092	29.162	628	672	234.82
MACH4	2022-01-02	16:34:40	114.093	29.161	628	673	234.92

利用构建的时空协同航迹预测模型实现实验四旋翼无人机的时空协同航迹预测。对采集的航迹数据实施预处理与表示学习后, 将其中的 70% 作为训练集, 20% 作为验证集, 10% 作为测试集。在模型中, 将缩放点击自注意力层的注意力头数量设置为 8 。对航迹以 10 s 为单位采用后, 每条航迹的数据点数量根据飞行时长不等, 在 $300\sim 1\ 500$ 之间。为了便于模型处理, 将变长的航迹通过滑窗的方式处理成定长的序列。假定本次航班有 300 个数据点, 以 50 个数据点作为模型训练的一个样本, 采用滑窗的方式, 滑窗

大小设置为 5 , 构造出 N 条样本, 具体如表 3 所示。

表 3 构造样本

样本编号	起始行号	结束行号	数据点数量
1	1	50	50
2	5	55	50
3	10	60	50
...
$N-1$	245	295	50
N	250	300	50

以真实的坐标值计算损失预测效果并不好, 这里使用了相对坐标。以输入的 50 个数据点的最后一个坐标点为原点, 其余的 49 个坐标点都和这个点的坐标 (例: $114.093, 29.161$) 相减, 得到输入数据的相对坐标。

对于模型训练, 源数据 (src) 是前 50 行数据, 目标数据 (tgt) 是后 50 行数据。这样, 模型在给定前 50 个数据点的情况下会尝试预测后 50 个点。该模型接收时间与空间两个方向上的输入数据。

3.2 评价指标

在测试中, 将四旋翼无人机在线规避航迹规划方法 (本文方法)、基于改进人工势场法 (文献 [4]) 与基于 LSTM 的四旋翼无人机轨迹预测方法作为对比测试方法 (文献 [5]), 共同性能实施测试, 并分别用方法 1、方法 2 来表示文献 [4] 和 [5]。

首先测试 3 种方法对于某条数据的直观预测结果, 接着测试并计算模型的整体预测效果。模型效果以验证集所有数据的平均误差值来评价。比如验证集有 100 条数据, 其中每条数据的输出是 50 个坐标点。那么首先求出单条数据 50 个点的均方误差, 然后求出验证集所有数据的均方误差。

3.3 测试结果

3.3.1 预测效果分析

首先测试 3 种方法的直观预测结果, 具体如图 3 所示。

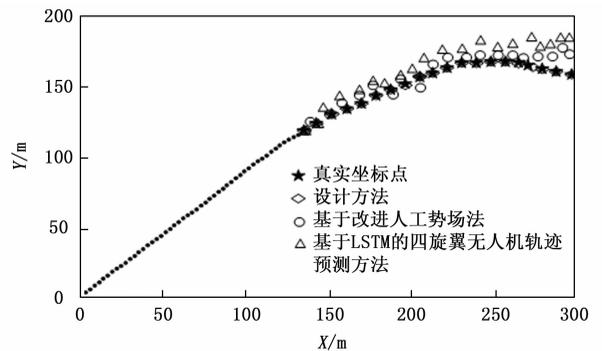


图 3 3 种方法的直观预测结果

图 3 中, 黑色实心点是前 50 个坐标点、实心五角星是真实的后 50 个坐标点、菱形是模型预测的坐标点、空心圆是基于改进人工势场法的预测坐标点、空心三角形是基于 LSTM 的四旋翼无人机轨迹预测方法的预测坐标点, 可以

看出设计方法预测结果虽然相对于真实的坐标点稍有偏差，但是整体结果在可接受范围内。而另外 2 种预测结果相对于真实的坐标点则偏差较大。

3.3.2 预测误差分析

均方误差是一种表示预测值与真实值之间平均误差值的测试指标，它计算预测值与真实值之间的平方差，并取平方根，数值越低，表明方法的预测误差越低。以均方误差为测试指标，对比设计方法与方法 1、方法 2 的整体预测效果如表 4 所示。

表 4 整体预测效果对比

数据条数	验证集所有数据的均方误差/m		
	设计方法	方法 1	方法 2
50	0.21	0.38	0.40
100	0.25	0.42	0.43
150	0.27	0.46	0.45
200	0.29	0.48	0.47
250	0.30	0.51	0.48
300	0.32	0.55	0.50

根据表 4 测试结果，设计方法验证集所有数据的均方误差在数据条数为 300 时仅为 0.32 m，而方法 2、方法 1 分别为 0.55 与 0.50，说明设计方法的整体预测效果误差较低，这是因为 Transformer 模型具备较强的学习和表示能力，它能够捕捉到输入数据中的长程依赖关系和复杂的时空关联，从而能够更精确地进行航迹预测。

3.3.3 预测能力分析

R 方是衡量预测方法拟合优度的指标，表示方法所解释的数据方差的比例。R 方的取值范围在 0~1 之间，越接近 1 表示模型能越好地拟合数据。为此，以 R 方为测试指标，验证 3 种方法的预测能力，测试结果如图 4 所示。

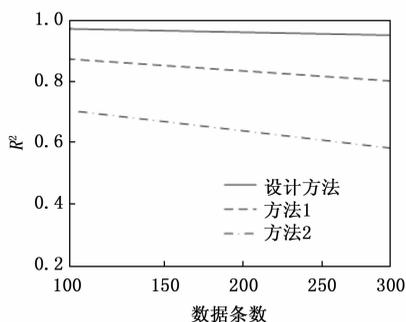


图 4 3 种方法的 R 方测试结果

由图 4 可知，3 种方法随着数据条数的增加，R 方测试结果均有下降的趋势。但设计方法的 R 方测试结果始终在 0.9 以上，最接近 1，相比之下，方法 1 和方法 2 的测试结果略低一些。由实验结果可知，设计方法的预测能力最好，这是因为 Transformer 模型通过自注意力机制可以直接关注任意位置的信息，从而有效地捕捉全局上下文信息，更好地建模长程依赖关系，有助于提高模型的拟合能力，使预

测能力好。

4 结束语

在无人机技术的快速发展和广泛应用背景下，针对四旋翼无人机协同航迹预测的问题，提出了一种基于 Transformer 模型的时空协同航迹预测方法，详细阐述了该方法的模型设计和实验过程。通过对原始航迹数据异常点剔除与插值补缺方法，从而提高数据的完整性。结合深度学习和表示学习，设计出四旋翼无人机航迹预测的数据降维方法，基于 Transformer 模型实现无人机时空协同航迹的精准预测。采取对四旋翼无人机实施时空协同航迹预测，以测试设计方法的预测性能，实验结果表明，该方法提高预测准确性，并具备较好的灵活性和扩展性，使得模型在处理复杂的无人机航迹预测任务时具备更强的表达能力和性能优势。相较于传统的方法，所提出的方法能够更好地处理四旋翼无人机动态行为的不确定性和复杂性，更准确地预测未来航迹，同时减少计算时间和计算成本。未来，将针对四旋翼无人机的特性和应用场景，对 Transformer 模型实施优化和调整，进一步提高模型的表示能力和适应性。将研究如何将更多的先验知识和任务信息融入模型中，以进一步提高模型的预测准确性和鲁棒性。

参考文献:

- [1] 向朝兴, 茅健. 四旋翼无人机的旋翼空气动力学建模与仿真[J]. 计算机仿真, 2021, 38(10): 48-52.
- [2] 侯鹏森, 肖支才, 刘玄冰, 等. 基于改进非线性制导律的无人机航迹跟踪算法研究[J]. 电光与控制, 2023, 30(6): 8-14.
- [3] 赵文娇, 甘旭升. 四旋翼无人机在线规避航迹规划方法[J]. 弹箭与制导学报, 2022, 42(5): 92-97.
- [4] 邓叶, 姜香菊. 基于改进人工势场法的四旋翼无人机航迹规划算法[J]. 传感器与微系统, 2021, 40(7): 130-133.
- [5] 陆佳欢, 曹宇轩, 羊钊, 等. 基于 LSTM 的四旋翼无人机航迹预测方法[J]. 哈尔滨商业大学学报: 自然科学版, 2022, 38(6): 699-704.
- [6] 程千顷, 王红军, 丁希成, 等. 基于迁移集成学习的无人机图像识别算法[J]. 电讯技术, 2023, 63(9): 1277-1284.
- [7] 鲁亮亮, 代冀阳, 应进, 等. 基于 APSODE-MS 算法的无人机航迹规划[J]. 控制与决策, 2022, 37(7): 1695-1704.
- [8] 高俊山, 段立勇, 邓立为. 四旋翼无人机抗干扰航迹跟踪控制[J]. 控制与决策, 2021, 36(2): 379-386.
- [9] 孙谷昊, 曾庆双, 蔡中泽. 四旋翼无人机安全航迹跟踪控制[J]. 控制理论与应用, 2023, 40(7): 1261-1269.
- [10] 韦为, 吴艳, 李芳, 等. 基于改进自抗扰的四旋翼无人机航迹跟踪控制[J]. 电工电能新技术, 2023, 42(5): 1-13.
- [11] 曾子元, 李云桓. 基于扩张状态观测器的四旋翼无人机飞行控制系统研究[J]. 微特电机, 2022, 50(1): 41-44.

(下转第 70 页)