



融合 STFT 和多流动态网络的空战轨迹预测方法

岳圣智¹, 邓向阳², 付宇鹏², 徐俊¹, 宋婧菡¹, 林远山^{1*}

(1.大连海洋大学 信息工程学院, 辽宁 大连 116023; 2.海军航空大学, 山东 烟台 264001)

摘要:现代空战对抗过程的复杂多变使得空战决策模糊多变,有效的轨迹预测能够极大提升决策的准确性。针对空战轨迹预测中复杂时间序列的特性,提出了一种融合短时傅里叶变换(STFT)与多流 Transformer 网络的轨迹预测方法,旨在提高空战机动轨迹预测的精度。空战机动过程中,飞行器的轨迹变化频繁且复杂,因此,首先通过高阶差分对轨迹数据进行预处理,以消除噪声并保留轨迹的时空特征。随后,利用短时傅里叶变换对预处理后的轨迹进行频域特征提取,分析轨迹的动态变化。为了更好地捕捉位置轨迹和姿态轨迹的差异性,设计了轨迹解耦策略,将这两类轨迹分开处理。接着,基于多流动态注意力机制的 Transformer 网络处理这些时空特征,从而实现对飞行轨迹中深层依赖关系的捕捉。该网络通过多头注意力机制对多个数据流进行加权处理,增强了模型对不同数据流的时空依赖关系的捕捉能力。实验结果表明,相比传统的预测方法,该文提出的方法预测精度提高了 3.88%; STFT 与多流 Transformer 结合的方法有效提高了对复杂空战机动轨迹的预测精度,验证了其在高精度空战场景预测中的适用性。

关键词:轨迹预测;多维特征处理;短时傅里叶变换

中图分类号:V249 **文献标志码:**A **文章编号:**1004-499X(2025)01-0060-08

Air-combat Trajectory Prediction Method Integrating STFT and Multi-stream Dynamic Network

YUE Shengzhi¹, DENG Xiangyang², FU Yupeng², XU Jun¹, SONG Jinghan¹, LIN Yuanshan^{1*}

(1.School of Information Engineering, Dalian Ocean University, Dalian 116023, China;

2.Aviation University Combat Services College, Yantai 264001, China)

Abstract: The complexity and changeability of modern air-combat confrontation makes air-combat decisions fuzzy and changeable. Effective trajectory prediction can greatly improve the accuracy of decision-making. Aiming at the characteristics of complex time series in air-combat trajectory prediction, a trajectory prediction method integrating short-time Fourier transform(STFT) and multi-stream transformer network was proposed to improve the accuracy of predicting air-combat maneuver trajectory. During air-combat maneuvers, the trajectory of aircraft changes frequently and complexly. Therefore, the trajectory data were first preprocessed by high-order difference to eliminate noise and retain the spatiotemporal characteristics of trajectory. Subsequently, the short-time Fourier transform was used to extract frequency-domain features of the preprocessed trajectory and analyze the dynamic changes of the trajectory. In order to better capture the differences between position trajectory and attitude trajectory, a trajectory decoupling strategy was designed to process these two types of trajectories separately. Then, the transformer network based on the multi-stream dynamic attention mechanism was used to process these spatiotemporal features, thereby capturing the deep dependencies in the flight trajectory. The network weights multiple data streams through multi-head attention mechanism, enhancing the model's ability to capture the

收稿日期:2023-08-02

基金项目:辽宁省教育厅基本科研项目(LJKZ0730, QL202016);辽宁省自然科学基金资助计划(2020-KF-12-09);辽宁省重点研发计划(2020JH2/10100043);山东省自然科学基金青年基金(ZR2024QF094)

*通信作者邮箱:Linyuanshan2008@126.com。

spatiotemporal dependencies of different data streams. Experimental results show that compared to traditional prediction methods, the proposed method has a 3.88% improvement in prediction accuracy. The combination of STFT and multi-stream transformer effectively improves the prediction accuracy of complex air-combat maneuver trajectory, verifying its applicability in high-precision air-combat scene prediction.

Key words: trajectory prediction; multidimensional feature processing; short-time Fourier transform

随着现代空战的快速发展,战斗机的机动性能不断提升,使得空中交战的复杂性和不确定性显著增加。预测空战目标的机动轨迹对于提高战术决策的质量、确保空中作战安全以及提升战斗效率具有重要意义。传统的轨迹预测技术,如粒子滤波方法,存在预测精度低的问题,文献[1]提出了基于 Elman 神经网络的方法进行预测,但 Elman 网络因其时间依赖性和训练数据不足,表现出泛化能力不足的问题。文献[2]提出了一种由改进灰狼算法优化的无迹卡尔曼滤波算法,可以有效提高预测精度。文献[3]提出了一种基于 GRU 的飞行轨迹预测方法,通过坐标变换实现任意初始位置和航向的轨迹预测。文献[4]结合动力学和灰色系统的方法进行轨迹预测,文献[5]在预测控制器中引入时间前移的有限时域优化策略,提升控制行为的效果。这些方法强调物理可解释性,计算速度快,但在处理复杂或非线性问题时适应性较差。

神经网络预测技术,如文献[6]的 BP 神经网络,存在结构局限性,导致预测误差较大。文献[7]提出利用隐马尔科夫模型进行轨迹预测,文献[8~9]提出结合遗传算法和粒子群优化算法进行预测,文献[10]结合最优引导律和递归最小二乘法提高命中率。文献[11]通过卷积神经网络对行人轨迹进行预测,但相较于 LSTM 网络,预测误差较大。文献[12]提出基于误差修正的广义回归神经网络预测算法,文献[13]提出基于多任务学习模型的 CNN 和双向 LSTM 并联方法进行船舶轨迹预测。这些深度学习技术在处理高维数据和非线性问题上表现出色,但需要大量的训练数据和计算资源,且通常缺乏物理可解释性。

因此,本文提出融合短时傅里叶变换,对三维飞行轨迹数据进行从时域到频域的转换,使用动态注意力机制提高模型对时间序列数据中关键信息的捕捉能力。使用多流 Transformer 网络对经度和纬度位置信息进行预测,通过结果对比与误差分析验证所提模型的有效性^[14]。短时傅里叶变换提供的频率特征增强了网络对数据中快速变化部分的敏感

性,多流动态网络结构可以同时处理和学习来自不同特征流的信息,提高了预测的准确性和鲁棒性。实验结果表明,模型具有较高的预测精度,对空战过程中我方飞机产生轨迹的多维信息的数据进行分析,实验验证了模型的有效性。

1 空战机动轨迹预测问题描述

针对一对一的空战近距离格斗机动轨迹预测问题,首先给定包含红蓝双方各自的历史轨迹点。目标是预测未来的轨迹,每个轨迹点代表在某一时间点的位置,即三维空间中的坐标。轨迹 $\mathbf{X}$ 为

$$\mathbf{X}_{n+1:n+m} = \begin{pmatrix} x_{n+1} & y_{n+1} & z_{n+1} \\ x_{n+2} & y_{n+2} & z_{n+2} \\ \vdots & \vdots & \vdots \\ x_{n+m} & y_{n+m} & z_{n+m} \end{pmatrix} \quad (1)$$

首先,系统状态在连续的时间点上更新。考虑动态系统受到控制输入和外部扰动的影响,系统的状态转移描述为

$$x_{i+1} = f(x_i, u_i, w_i) \quad (2)$$

式中: x_i 为系统在时间点 i 的状态, u_i 为在时间点 i 的控制输入, w_i 为在时间点 i 的外部扰动, f 为状态转移函数。该函数描述系统基于当前状态、控制输入和外部扰动更新到下一个状态。预测模型函数基于历史轨迹 $\mathbf{X}$,将状态向量在多个时间点上的集合进行建模。其中历史轨迹 $\mathbf{X}$ 的行表示不同的时间点,列表示不同的状态变量。结合历史轨迹矩阵 $\mathbf{X}$ 和控制输入序列 $\mathbf{U} = (u_1 \ u_2 \ \cdots \ u_n)$ 来预测未来的状态:

$$\mathbf{Y} = g(\mathbf{X}, \mathbf{U}) \quad (3)$$

式中: $\mathbf{Y}$ 为未来轨迹的预测,而函数 g 需要能够捕捉飞行器动态系统的复杂行为,包括对未来外部扰动 $w_{n+1}, w_{n+2}, \cdots, w_{n+m}$ 的反应。

2 基于 STFT 多流动态网络轨迹预测方法

2.1 总体框架

在探索空战轨迹预测的先进方法中,本文提出一

个基于深度学习的架构,旨在处理和分析复杂的空战数据^[15]。模型预测方法的组成部分,如图1所示。




图1 预测方法总流程

Fig. 1 Total flow chart of forecasting method

2.2 数据特征提取

在空战过程中,各个维度之间的相关性关系表明了信息的复杂性。复杂的关系网络表明,单一的分析模型不足以捕捉到所有的信息特征^[16-17]。通过计算皮尔逊系数可得空战过程中每个维度之间的相关性信息,如图2所示。




图2 空战机动多维度相关矩阵

Fig. 2 Air-combat maneuver multi-dimensional correlation matrix

如图2所示,多数任意两维度之间的相关性较低^[18]。为了发现轨迹的动态特性和维度之间的潜在模式,本文通过高阶差分将归一化预处理后的数据进行从时域转换到频域转换,从而揭示轨迹的复杂特征,并通过对高阶差分后的数据进行短时傅里叶变换,进行数据特征提取,表达式为

$$\nabla^d T_t = \nabla (\nabla^{d-1} T_t) \quad (4)$$

$$\nabla^d T_t = \sum_{k=0}^d (-1)^k \binom{d}{k} T_{t-k} \quad (5)$$

$$S_{k,m} = \sum_{n=0}^{N-1} T[n] \omega[n-m] e^{-j2\pi k \frac{n}{N}} \quad (6)$$

式中: d 为高阶差分的阶数, T_t 为时间序列数据, ∇^d 表示第 d 阶差分的梯度。对 T_t 进行多次差分运算,以提取更深层次的动态特性。 k 为离散频率指数, m 为窗函数相对于信号起始点的离散时间偏移, N 为窗口长度, $\omega[n-m]$ 为离散时间窗函数, $T[n]$ 为离散时间。

2.3 动态自注意力机制

由于普通传统 Transformer 的自注意力机制权重分配无法充分适应复杂的空战环境,提出动态注意力机制,来进一步提高模型对时间序列数据中关键信息的捕捉能力,如图3所示。




图3 动态自注意力机制网络

Fig. 3 Dynamic self-attention mechanism network

动态自注意力机制的核心思想是:通过使用全连接层和 ReLU 激活函数,根据输入数据的均值生成动态权重。使用动态权重对输入数据进行调整,使注意力机制能够灵活适应不同的输入。如图3所示,将生成的动态权重逐元素乘入输入数据,得到调整后的查询向量 Q 、键向量 K 和值向量 V 。使用标准的缩放点积注意力机制,计算调整后的查询向量和键向量的点积,进行缩放和 softmax 转换,再与调整后的值向量进行矩阵乘法。其动态调整因子的计算公式为

$$Q' = Q \odot D^Q, K' = K \odot D^K, V' = V \odot D^V \quad (7)$$

$$A' = \text{softmax} \left(\frac{Q' K'^T}{\sqrt{d_k}} \right) \quad (8)$$

$$O' = A' V' \quad (9)$$

式中:“ $\odot$ ”表示逐元素乘法; D 为用于对 Q, K, V 向量进行动态加权调整的因子,帮助模型更好地捕捉输入数据中的特性,调整因子允许模型根据输入数据的特点动态调整自身的注意力权重; A' 为经过动态调整后的注意力权重矩阵; O' 为最终的输出,包

含了输入数据的动态特性。

2.4 MSTN 预测模型架构

多数据流 Transformer 网络结构 (multi-stream transformer network, MSTN) 如图 4 所示,由于空间信息和姿态信息具有不同的物理意义^[19],混合处理造成信息误解。引入多流 Transformer 网络,通过为不同信息设置独立的输入流避免这种干扰,从而更加准确地提取和处理不同维度的信息。架构由两个核心组成部分构成:一是负责处理空间位置信息(如经度、纬度、高度和速度)的空间流 Transformer 网络 (spatial stream transformer, SST);二是负责处理飞行姿态信息(如航向角、俯仰角和滚转角)的姿态流 Transformer 网络 (attitude stream transformer, AST),网络结构如图 4 所示。




图 4 MSTN 网络结构

Fig. 4 Multi-stream transformer network structure

空战数据首先会通过输入嵌入层进行编码,然后嵌入层输出被送入多头注意力机制中,加法与规范化层被应用于注意力层的输出,与输入嵌入相加以形成残差连接。通过前馈网络,接受加法与规范化层的输出。最后, MSTN 的输出由空间流和姿态流的输出通过全连接层结合而成。MSTN 架构在多个维度上深入理解复杂数据的内在结构,保持对各个数据流特有特性的敏感性。架构可处理多维序列数据,特别是对空战中大机动战术过程中的数据流进行学习。SST 和 AST 都有自己的输入嵌入层。输入嵌入层将原始输入数据转换为适合 Transformer 模型处理的高维空间,嵌入包括位置编码,以保持输入数据的序列信息。而且在 MSTN 架构中,AST 和 SST 处理不同的数据类型,因此 Q, K, V 矩阵会根据各自流的数据类型和上下文来变化。在训练过程中,通过反向传播算法调整这些权重矩阵,使模型可以更好地预测输入数据。AST 和 SST 的 Q, K, V 矩阵根据输入数据和训练过程中学习到的权重生成,


并在多头注意力机制中用于捕获不同级别的特征和序列内的依赖关系。

3 实验与分析处理


3.1 空战数据特征提取

图 5 为短时傅里叶变换在飞行高度数据中的应用^[20],展示不同频率下数据随时间的变化情况,从而揭示潜在的周期性或突发性的变化。

图 5(a)为直接使用原始数据进行短时傅里叶变换的数据特性图,如图所示直接变换后无法发现数据的特性;图 5(b)为经过高阶差分处理后使用短时傅里叶变换处理的空战原始数据,显示出在 0.3 Hz 频率的活动特性。对比两图,进一步证明,经过短时傅里叶变换进行了适当的噪声滤除处理后,数据的质量得到提升并可以获取到数据的频域特性。



(a) 原始数据变换



(b) 高阶差分数据变换

图 5 原始数据与高阶差分数据经过短时傅里叶变换结果对比

Fig. 5 Comparison of the short-time Fourier transform results between original data and high-order differential data

3.2 动态注意力机制误差

图 6 为标准自注意力机制与动态自注意力机制网络在不同时间步长下的误差值对比。该图展示出两种注意力机制在处理数据时的误差变化情况。




图 6 标准与动态自注意力机制网络误差值对比
Fig. 6 Comparison of network error values between standard and dynamic self-attention mechanisms

由图 6 可知,在时间步长为 50 时,标准注意力机制方法的误差约为 1.21,而动态注意力机制方法的误差约为 0.43,误差减少了 67.5%。在时间步长为 100 时,采用标准注意力机制方法的误差峰值接近 1.61,而采用动态注意力机制的误差峰值低于 0.83,误差减少了 50.3%。动态注意力机制预测误差大幅减少,预测准确度有一定提升。

3.3 实验设置与结果分析

实验计算机的配置为 Intel i7-9700F CPU,NVIDIA RTX 2070S GPU,32 GB 运行内存。在仿真中运用 Python3.7 程序设计语言,专业版 Pycharm,pytorch 深度学习框架。使用 CUDA 加速 GPU 的计算速度,确保 Pytorch 可以在 GPU 上高效运行,使用 Numpy 和 Scipy 库用于数据的数值处理。模型训练采用了交叉验证和提前停止方法,以避免模型过拟合。

3.3.1 实验数据集

实验的数据集来源于 20 位飞行员在座舱模拟器中进行的空战科目操作。模拟器在真实的飞行环境下,对飞行数据进行了高频采样,以 50 s^{-1} 的频率记录下飞行器的动态信息。数据包括飞机的三维空间位置(经度、纬度、高度)和姿态信息(航向角、俯仰角、滚转角),提供了运动学信息用于轨迹预测和分析。由于实验数据集使用每个飞行员在模拟器中进行空战对抗训练产生的大量轨迹数据,为了保证模型的泛化能力,数据需要集经过预处理和标准化操作。首先,去除噪声和异常点,确保数据的准确性。然后将数据按照时间序列进行划分,以便模型能够学习到飞行轨迹的时序特性。最终的数据集被分成训练集、验证集和测试集,确保模型能够在未见过的数据上进行准确地预测^[20-21]。

3.3.2 超参数选择

设置采样频率为 50 Hz,双方飞机的数据共加载 10 832 条数据。按 6:2:2 比例划分为训练集、验证集、测试集,网络结构组参数如表 1 所示,采样频率为 50 Hz。我方飞机的数据为 10 832 条,选用 8 664 条作为训练集,其余 2 168 条作为测试集。模型训练超参数设置如表 1 所示。

表 1 模型训练超参数

Table 1 Model training hyperparameters		
符号	定义	取值
num_layers	神经网络层数	6
dim_model	模型维度	512
nhead	多头注意力数	8
dim_forward	前馈网络	4 096
dropout	正则化系数	0.05
epoch	回合数	5 000

在 MSTN 架构下预测的准确性如图 7 所示,图 7(a)、图 7(b)代表不同的机动十个时间步长的预测结果,模型的预测将显示模型的输出与实际飞行路径的匹配程度。模型准确预测机动,预测数据点紧密跟随实际数据点。




图 7 三维机动预测结果

Fig. 7 Three-dimensional multi-maneuver prediction results

由图 7 可知,MSTN 预测轨迹在多数点上与实际轨迹相差很小,具有较高的预测精度,特别是在方向的改变和转弯点上。MSTN 方法在处理动态环境和快速反应方面更有效。可见 MSTN 在这些预测图中显示出对实际轨迹的良好预测能力,尤其是在轨迹紧凑度和转弯性能方面。

对空战轨迹的经纬度预测结果分析如图 8 所示,对比 MSTN 与 Transformer 两种方法在不同时间步长上的预测表现。进一步证明 MSTN 方法在轨迹预测任务中的精度提升效果。




图 8 经度-纬度预测结果

Fig. 8 Longitude-latitude prediction results

分析结果可知,虽然整体预测较为准确,但从图 8(a) 的经度预测结果显示,MSTN 网络架构与真实轨迹有一定细微偏差。在第 3 个时间步长上,Transformer 预测方法与 MSTN 预测方法较真实轨迹相差 3.36%。在第 6 个时间节点,MSTN 的纬度预测结果与真实值相差 4.3%,优于 Transformer 方法。可以看到,在多数时间点上,相比于 Transformer,MSTN 的预测结果与真实轨迹的差异更为细微。对于图 8(b) 纬度预测结果的第 7 个时间点,MSTN 方法的效果明显优于 Transformer 方法,进一步表明了 MSTN 在预测准确性上的优势。

图 9 为 MSTN 模型和 Transformer 模型在 10 个

时间步长上的均方根误差对比情况。




图 9 均方根误差损失对比

Fig. 9 Root mean square error loss

Transformer 和 MSTN 数据系列之间的平均差值为 0.205 2。平均而言,Transformer 系列中的损失值比 MSTN 系列高 0.205 2。两个系列之间观察到的最大差异为 0.742 9。最小的百分比差异为 3.88%,对于两种预测方法最小的差异,Transformer 方法中的值也比 MSTN 方法中的值至少高出 3.88%。这是 Transformer 系列中的单个数据点超过其在 MSTN 系列中对应点的最大差距。存在一个最小差异为 -0.183 1,仅在一个实例中,MSTN 系列的误差值高于 Transformer 系列。差异的标准差为 0.261 5,表示平均差异的变化量。

图 10 为不同轨迹预测模型在多个维度上的预测效果对比。从图 10 对三维空间我方飞机飞行轨迹预测可以看出,MSTN 模型在飞行轨迹预测中相比于 Transformer 和 LSTM 神经网络,MSTN 模型的平均误差为 2.3,而 Transformer 模型为 4.5,LSTM 模型为 7.8。MSTN 模型在 X 轴上的预测轨迹几乎与实际轨迹完全重合,显示出极高的精确度。在 Y 轴上,MSTN 模型的平均误差为 1.9,Transformer 模型为 3.8,LSTM 模型为 6.2。MSTN 模型在此维度的预测效果同样优越。由于 Z 轴曲线变化较剧烈,MSTN 模型的平均误差为 3.2,Transformer 模型为 5.9,LSTM 模型为 8.4。MSTN 模型仍明显优于其他两种模型。因此,基于 MSTN 的飞行轨迹预测模型在预测精度上具有更显著的优势,MSTN 方法的数值指标和预测表现表明,其在高精度轨迹预测应用中具有很高的实用价值。




图 10 轨迹模型预测结果

Fig. 10 Track model prediction results

4 结束语

本文针对空战轨迹预测中的数据特征复杂性和多维特征处理难题,提出了一种结合 Transformer 模型与多数据流处理的先进预测方法;利用短时傅里叶变换提取飞行行为的特征;通过多数据流动态注意力机制的 Transformer 网络,捕获深层时空依赖关系,从而提高预测准确度。实验结果表明,该方法在处理一对一空战场景数据时,相比传统方法,预测精度提高了 3.88%。

参考文献

- [1] 张涛,郭基联,徐西蒙,等. 基于 Elman 神经网络的战斗机空战轨迹预测[J]. 飞行力学,2018,36(5):86-91.
ZHANG Tao, GUO Jilian, XU Ximeng, et al. Prediction of fighter air combat trajectory based on Elman neural network[J]. Flight Mechanics, 2018, 36(5): 86-91. (in Chinese)
- [2] 游航航,余敏建,吕艳,等. 基于改进灰狼算法优化的 UKF 在空战轨迹预测中的应用[J]. 战术导弹技术,2020(1):91-98.
YOU Hanghang, YU Minjian, LV Yan, et al. Application of UKF based on improved grey wolf algorithm optimization in air combat trajectory prediction[J]. Tactical Missile Technology, 2020(1): 91-98. (in Chinese)
- [3] 张宏鹏,黄长强,轩永波,等. 用门控循环单元实时预测空战飞

- 行轨迹[J]. 系统工程与电子技术,2020,42(11):2546-2552.
ZHANG Hongpeng, HUANG Changqiang, XUAN Yongbo, et al. Real-time prediction of air combat flight trajectory using gated recurrent unit[J]. Systems Engineering and Electronics, 2020, 42(11): 2546-2552. (in Chinese)
- [4] WANG Q Y, ZHANG Z L, WANG Z Y, et al. The trajectory prediction of spacecraft by grey method[J]. Measurement Science and Technology, 2016, 27(8): 085011.
- [5] 张丽珍,顾素郡,吴迪. 基于改进的投饵船模型预测轨迹跟踪控制[J]. 制造业自动化,2021,43(10):68-74.
ZHANG Lizhen, GU Sujun, WU Di. Predictive trajectory tracking control based on an improved bait-casting ship model[J]. Manufacturing Automation, 2021, 43(10): 68-74. (in Chinese)
- [6] 钱夔,周颖,杨柳静,等. 基于 BP 神经网络的空中目标航迹预测模型[J]. 指挥信息系统与技术,2017,8(3):54-58.
QIAN Kui, ZHOU Ying, YANG Liuqing, et al. Air target track prediction model based on BP neural network[J]. Command Information System and Technology, 2017, 8(3): 54-58. (in Chinese)
- [7] QIAO S J, SHEN D Y, WANG X T, et al. A self-adaptive parameter selection trajectory prediction approach via hidden Markov models[J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16(1): 284-296.
- [8] 谭伟,陆百川,黄美灵. 神经网络结合遗传算法用于航迹预测[J]. 重庆交通大学学报(自然科学版), 2010, 29(1): 147-150.
TAN Wei, LU Baichuan, HUANG Meiling. Neural network

- combined with genetic algorithm for track prediction[J]. Journal of Chongqing Jiaotong University (Natural Science Edition), 2010, 29(1):147-150. (in Chinese)
- [9] WU Zhijun, TIAN Shan, MA Lan. A 4D trajectory prediction model based on the BP neural network [J]. Journal of Intelligent Systems, 2019, 29(1):1545-1557.
- [10] AKCAL M U, URE N K, YANG C G, et al. Predictive missile guidance with online trajectory learning [J]. Defence Science Journal, 2017, 67(3):332-338.
- [11] NIKHIL N, MORRIS B T. Convolutional neural network for trajectory prediction[C]//Proceedings of ECCV 2018 Workshops. Switzerland: Springer, 2018:186-196.
- [12] 杨彬, 贺正洪. 一种 GRNN 神经网络的高超声速飞行器轨迹预测方法[J]. 计算机应用与软件, 2015, 32(7):239-243.
- YANG Bin, HE Zhenghong. A hypersonic vehicle trajectory prediction method based on GRNN neural network[J]. Computer Applications and Software, 2015, 32(7):239-243. (in Chinese)
- [13] 杨红, 韩鹏, 刘畅, 等. 基于多任务学习的船舶行为识别与轨迹预测[J]. 重庆交通大学学报(自然科学版), 2022, 41(4):1-7.
- YANG Hong, HAN Peng, LIU Chang, et al. Ship behavior recognition and trajectory prediction based on multi-task learning[J]. Journal of Chongqing Jiaotong University (Natural Science Edition), 2022, 41(4):1-7. (in Chinese)
- [14] 李朋洋. 基于时间序列预测的多级意图理解建模方法研究[D]. 长春:吉林大学, 2024.
- LI Pengyang. Research on multi-level intention understanding modeling method based on time series prediction[D]. Changchun: Jilin University, 2024. (in Chinese)
- [15] 贾思程. 基于图注意力网络的飞行轨迹预测[D]. 西安:西安电子科技大学, 2023.
- JIA Sicheng. Flight trajectory prediction based on graph attention network[D]. Xian: Xidian University, 2023. (in Chinese)
- [16] 付宇鹏, 邓向阳, 朱子强, 等. 基于价值滤波的空战机动决策优化方法[J]. 航空学报, 2023, 44(22):20-33.
- FU Yupeng, DENG Xiangyang, ZHU Ziqiang, et al. Air combat maneuver decision optimization method based on value filtering[J]. Acta Aeronautica Sinica, 2023, 44(22):20-33. (in Chinese)
- [17] 付宇鹏, 邓向阳, 何明, 等. 基于强化学习的固定翼飞机姿态控制方法[J]. 控制与决策, 2023, 38(9):2505-2510.
- FU Yupeng, DENG Xiangyang, HE Ming, et al. Fixed-wing aircraft attitude control method based on reinforcement learning [J]. Control and Decision, 2023, 38(9):2505-2510. (in Chinese)
- [18] 魏渤杭. 基于强化学习的超视距空战自主机动决策算法研究[D]. 成都:电子科技大学, 2024.
- WEI Bohang. Research on autonomous maneuvering decision algorithm for beyond visual range air combat based on reinforcement learning [D]. Chengdu: University of Electronic Science and Technology of China, 2024. (in Chinese)
- [19] 黄挚行. 基于最大熵蒙特卡洛树搜索的围棋与基于高斯混合模型的空战算法研究[D]. 南宁:广西大学, 2024.
- HUANG Zhixing. Research on Go based on maximum entropy Monte Carlo tree search and air combat algorithm based on Gaussian mixture model[D]. Nanning: Guangxi University, 2024. (in Chinese)
- [20] 丁子瑞. 数据-模型双驱动的空战目标意图推理算法研究[D]. 西安:西安工业大学, 2024.
- DING Zirui. Research on air combat target intention reasoning algorithm driven by data and model[D]. Xi'an: Xi'an University of Technology, 2024. (in Chinese)
- [21] 郑天宇, 姚郁, 贺风华. 基于可学习 EKF 的高超声速飞行器航迹估计[J]. 哈尔滨工业大学学报, 2020, 52(6):160-170.
- ZHENG Tianyu, YAO Yu, HE Fenghua. Trajectory estimation of a hypersonic flight vehicle via L-EKF[J]. Journal of Harbin Institute of Technology, 2020, 52(6):160-170. (in Chinese)