

基于 Light Reverse Transformer 的空中目标意图识别方法

王科¹, 郭相科¹, 王亚男¹, 倪鹏², 权文³, 李成海¹

(1. 空军工程大学防空反导学院, 西安, 710051; 2. 复杂航空系统仿真重点实验室, 北京, 100076;

3. 空军工程大学空管领航学院, 西安, 710051)

摘要 空中目标意图识别在战场态势感知领域占据举足轻重的地位。然而, 如何从海量态势数据中迅速且精准地挖掘关键信息, 一直是该领域研究面临的一大难题。现有多数研究模型因架构繁复, 难以在短时间内高效地推断出目标意图。为解决这一难题, 基于 Transformer 架构进行设计, 通过 Reverse 方法优化模型以更适用于处理时间序列任务, 并在位置编码中融入扰动元素, 以提升模型的鲁棒性和泛化能力。此外, 对注意力机制和前馈神经网络进行了轻量化改进。经过对比实验、消融实验以及计算复杂度的深入分析, 所提模型在空中目标意图识别领域的有效性得到了有力验证。

关键词 意图识别; 深度学习; Transformer; 多头注意力机制

DOI 10.3969/j.issn.2097-1915.2025.03.012

中图分类号 V219; TP183 **文献标志码** A **文章编号** 2097-1915(2025)03-0096-10

A Method of Recognizing Air Target Intent Based on Light Reverse Transformer

WANG Ke¹, GUO Xiangke¹, WANG Yanan¹, NI Peng², QUAN Wen³, LI Chenghai¹

(1. Air Defense and Antimissile School, Air Force Engineering University, Xi'an 710051, China;

2. Science and Technology on Complex Aviation Systems Simulation Laboratory, Beijing 100076, China;

3. Air Traffic Control and Navigation School, Air Force Engineering University, Xi'an 710051, China)

Abstract Recognition of air target intent occupies a position of strategic importance in the realm of battlefield situational awareness. Nonetheless, how to quickly and accurately extract pertinent information from extensive situational data is still a question in this domain. The majority of prevalent research models are characterized by intricate architectures, hindering the efficient inference of target intentions within a concise timeframe. For the above-mentioned reasons, a model is introduced based on Transformer architecture. The model is optimized by Reverse method to adapt it further to handle time-series tasks. And, the integration of perturbation elements merged into the position encoding elevates the model's robustness and generalization capabilities. Additionally, this paper implements lightweight enhancements to both the attention mechanism and the feedforward neural network. By a comprehensive evaluation encompassing comparative experiments, ablation studies, and an in-depth analysis of computational complexity, the effi-

收稿日期: 2024-03-18

基金项目: 国家自然科学基金(62002362, 61703426); 陕西省高校科协青年人才托举计划(2019038); 陕西省创新能力支持计划(2020KJXX-065)

作者简介: 王科(1999-), 男, 重庆人, 硕士生, 研究方向为智能信息处理、态势感知。E-mail: wk_wkk0310@163.com

引用格式: 王科, 郭相科, 王亚男, 等. 基于 Light Reverse Transformer 的空中目标意图识别方法[J]. 空军工程大学学报, 2025, 26(3): 96-105. WANG Ke, GUO Xiangke, WANG Yanan, et al. A Method of Recognizing Air Target Intent Based on Light Reverse Transformer[J]. Journal of Air Force Engineering University, 2025, 26(3): 96-105.

cacy of the proposed model is unequivocally substantiated within the domain of airborne target intent recognition.

Key words intent recognition; deep learning; Transformer; multi-head attention

随着智能化时代的迅速发展和深入推进,空中力量的不断创新变革以及国际安全形势的日益错综复杂,空中目标意图识别问题的重要性和紧迫性愈发凸显,使得空中目标意图识别问题变得尤为紧迫且至关重要。同时,空中作战形态正逐步向信息化、智能化方向转变,导致空中战场环境愈发错综复杂,战场态势信息呈现指数式增长。在当前环境下,指挥员面临着从海量态势数据中迅速、准确提取关键信息的巨大挑战。因此,本文旨在设计一种轻量化、智能化的空中目标意图识别方法,为辅助指挥员高效决策提供新的思路与参考。

在当前学术研究背景下,空中目标意图识别问题已成为国内外众多学者关注的焦点,并积累了丰富研究成果。传统空中目标意图识别方法主要涵盖规则与模板匹配、模糊理论、D-S 证据理论以及贝叶斯网络等^[1-2]。在早期研究中,规则和模板匹配对于空中目标意图识别的自动化进程起到了重要作用。该方法通过汇总历史数据,构建了一套包含经验、知识、逻辑的可复用规则和模板,从而显著提高了目标意图识别的效率和准确性。然而,它过度依赖专家知识构建的规则库可能引入主观偏见,同时也面临着规则库维护成本高等问题^[3-5]。在处理历史数据或先验信息有限的问题时,模糊推理因其不依赖广泛先验知识构建概率模型而表现卓越。它能灵活管理定量和定性表征,实现二者间的顺畅转换。但面对高维数据或复杂场景,模糊推理可能受计算复杂性影响而效率受限^[6-8]。D-S 证据理论通过确定不同证据的概率分布,有效提升了意图识别的精确性。然而,它在处理冲突证据时存在困难,可能导致推理偏差。此外,该理论假设证据间相互独立,但在实际应用中,证据间的相关性或依赖性可能破坏这一假设,从而影响推理的准确性和可靠性^[9-12]。贝叶斯网络利用经验知识设定意图的先验概率,并通过收集新数据和概率推理来更新这些概率,从而更精确地识别目标意图。然而,构建精确且全面的贝叶斯网络需要大量数据和专家知识,推理计算复杂^[5,13-14]。上述传统方法在应对现代战场产生的大规模数据时存在显著局限性。尤其在当前信息爆炸的时代背景下,难以迅速且准确地判别目标意图。这些局限性都揭示出对更先进、更高效方法的迫切需求。

随着机器学习和深度学习方法研究的不断深

入,国内外众多学者开始将各种智能化方法广泛应用于空中目标意图识别领域研究中,旨在提高识别的准确性和效率,成为当前研究的重要方向。钱钊等^[15]在研究中考虑了空中目标运动状态信息的时间相关性,提出了一种基于长短时记忆神经网络的意图识别方法,显著提高了意图识别准确率。李颖等^[16]针对敌方状态信息呈现多维、海量的特点,设计了一种层次聚合模型,能够深刻表达意图的层次性以及意图之间的长时依赖关系,为处理复杂战场态势信息提供了新的有效方法。丁鹏等^[17]充分考虑了误判代价对作战决策的影响,针对性地设计了一种基于空中目标时序数据的 GRU-FCN 模型,旨在提升意图识别的准确性和效率。宋晓程等^[18]针对战场中空中目标航迹表现出的显著动态性、时序变化性以及意图多样性特点,提出了一种基于端到端类属属性学习的识别方法,作为多意图识别模型的基本框架,有助于作战筹划系统建立非合作目标与保卫要地的关联关系,为战场决策提供更可靠的信息支持。潘明等^[19]面对数据挑战,提出了深度双向门控循环单元(deep bidirectional GRU, DBG-RU)模型,并开发了一种小样本对比学习算法,结合数据增强和对比学习充分挖掘数据。赵亮等^[20]针对不平衡且难以分类的空中目标意图识别问题,提出了一种基于滑动窗口估计的时空卷积自注意力网络模型,有效提高了难分类样本的训练效率和意图识别准确率。

在当前空中目标意图识别研究中,循环神经网络、卷积神经网络等方法被广泛应用。然而,这些方法往往存在模型架构复杂、难以快速高效识别的问题。本文基于 Transformer 架构设计了一种轻量化方法,旨在提升意图识别准确率和效率,主要完成以下工作:

1) 传统 Transformer 模型通常采用 Encoder-Decoder 架构,然而这种架构更适用于自然语言处理等领域。本文针对时间序列数据的独特性质,仅采用 Encoder 部分作为模型的基础。此外,为了进一步提升模型在处理长序列时的性能,结合时间序列特征,对多头注意力机制和 ConvFFN 模块进行了 Reverse 操作,能够更有效捕捉时间序列中的长期依赖关系,挖掘战场态势数据中的深层特征信息。

2) 本文对传统位置编码方法进行了改进,旨在更真实模拟实际场景中的噪声数据。通过在传统位

置编码中融入高斯噪声,使得模型能够更好地应对含有噪声的输入数据,不仅显著增强了模型的鲁棒性和泛化能力,还能够有效提升模型在意图识别任务中的表现效果。

3)鉴于 Transformer 模型通常具有参数量大的特点,本文对多头注意力机制进行了特别的优化。通过引入一个映射层,降低模型的计算复杂度,从而在保持性能的同时,减少对计算资源的需求。此外,对传统的前馈神经网络层(feed forward network, FFN)也进行了改进,将卷积操作和跳跃连接融入其中,不仅有助于网络学习恒等映射,还能有效解决梯度消失问题。

1 空中目标意图识别问题描述

意图识别通常具备多种显著特性,包括抽象性、欺骗性、对抗性及稳定性等^[21]。抽象性体现在指挥员对整个战场态势的综合分析上,需要根据目标意图、作战计划等诸多因素进行推断。这种推断过程具有主观性,因此不同指挥员对同一目标的意图判断可能产生不同认知。欺骗性是意图识别中的重要方面,为防止敌方轻易识破己方作战意图,指挥员可能会制造具有迷惑性的假象来误导敌方。意图的对抗性主要存在于作战双方为实现各自意图而展开的激烈战斗中。稳定性指一旦意图确立,就不会轻易改变,体现了意图的持久性和坚定性。

空中目标意图识别问题的核心在于如何从海量飞行数据中提取出有用信息,进而推断出目标的作战意图。图 1 呈现空中目标意图识别的整个流程。雷达、无人机以及卫星等传感器负责收集目标对象的连续飞行数据。随后,这些数据会经过一系列精细化处理步骤,在处理过程中,筛选出有效特征,进而构建出时间序列数据集。最终,借助先进的人工智能算法模型,准确推测出目标的作战意图。

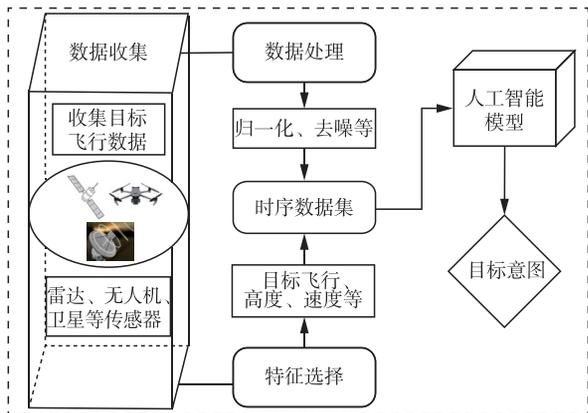


图 1 空中目标意图识别流程

Fig. 1 Process of air target intent recognition

通常,针对不同作战场景和目标特性,作战意图空间的定义呈现出一定差异性。丁鹏等^[17]根据防空作战的具体场景以及空中目标的独特特点,将空中目标的作战意图空间明确界定为攻击、突防、佯攻、干扰、监视、侦察以及撤退等多个方面。陈浩等人^[22]基于海上作战环境的复杂性和海上舰船编队的特殊性质,将海上舰船的作战意图空间确立为主要涵盖攻击、侦察、撤退 3 个核心要素。陆光宇等^[23]针对水下平台作战环境的独特性以及水下目标作战方式的特殊性,将水下目标的作战意图空间定义为攻击、撤离、巡逻等关键行动领域。本文针对空中目标的特点进行了研究,选取有效特征以构建相应的数据集和作战意图空间,构建方式如图 2 所示。本文选取了 7 种数值型特征和 5 种非数值型特征。具体而言,数值型特征包括飞行速度、目标相对距离、飞行高度、航向角、方位角、飞行加速度以及雷达反射截面积;非数值型特征涵盖空战能力因子、对地雷达状态、对空雷达状态、弹药携带状态以及敌机类别。此外,本文将攻击、突防、佯攻、监视、电子干扰、警戒以及后撤构建为意图空间。

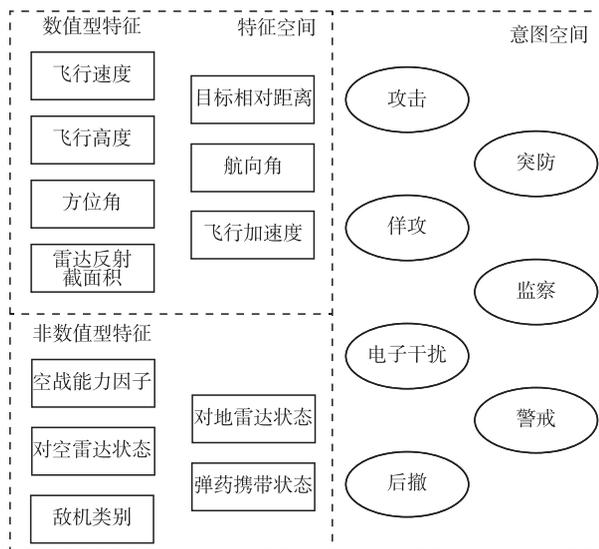


图 2 空中目标意图识别的特征空间和意图空间

Fig. 2 Feature space and intent space for air target intent recognition

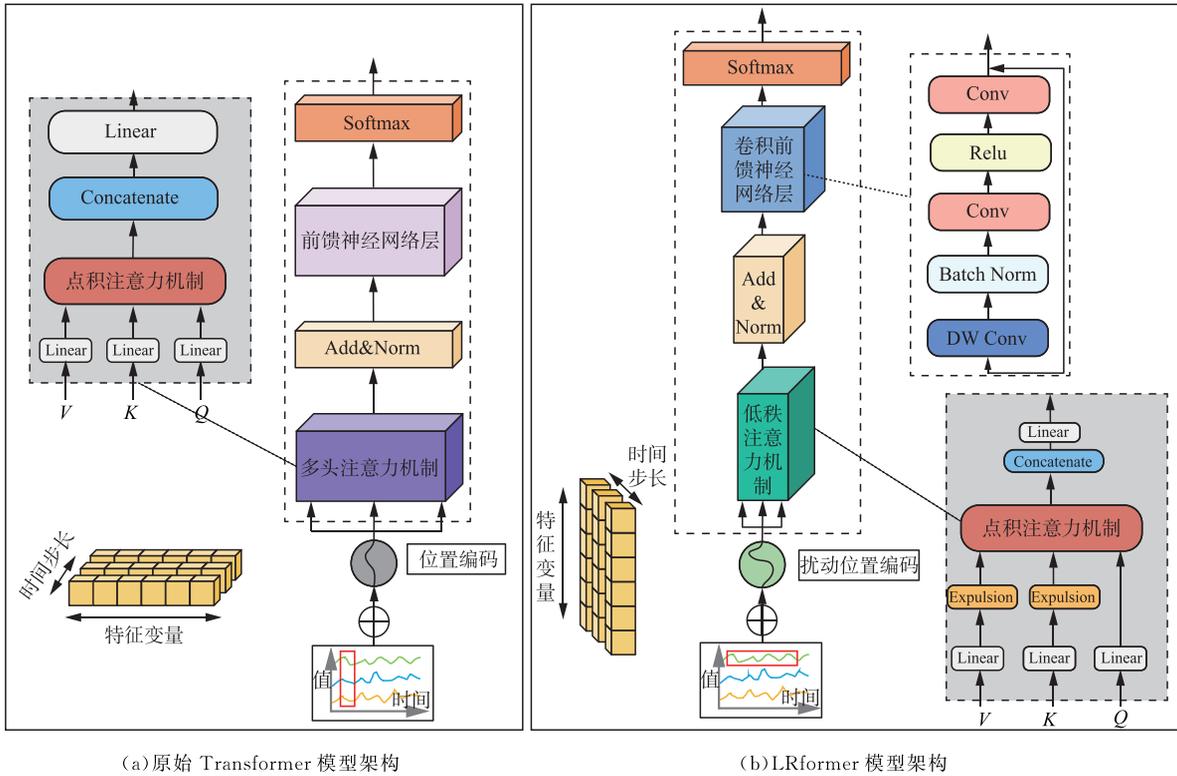
2 Light Reverse Transformer 模型

目前,多数研究主要依赖于分析目标在一段时间内的连续动作来推断其意图,这种方法实质上是通过对时间序列数据来挖掘目标的真实意图。然而,传统的意图识别方法可能面临诸多挑战,无法提取数据中的深层特征信息。为了更有效地解决这一问题,结合 Transformer 模型在时间序列领域的优异表现,本文针对 Transformer 模型进行了设计,提

出了 Light Reverse Transformer(LRformer),能够更准确地捕捉时间序列数据中的关键信息,进而实现更精准的空中目标意图识别。

图 3(a)和图 3(b)分别展示了原始 Transformer 模型和 Light Reverse Transformer 模型的架构图。相较于原始 Transformer 模型,LRformer 模型在注意力机制和前馈神经网络 FFN 模块的顺序上

进行了重要调整,进行了 Reverse 操作。原始 Transformer 模型主要关注于从输入序列中捕获同一时间步之间的相关性信息,而 LRformer 模型则侧重于捕捉不同时间步之间的信息交互。LRformer 模型的核心组成部分包括扰动位置编码、低秩注意力机制以及卷积前馈神经网络(convolutional feed forward network, ConvFFN)。



(a)原始 Transformer 模型架构 (b)LRformer 模型架构

图 3 原始 Transformer 和 LRformer 架构对比
Fig. 3 Comparison of Transformer and LRformer architectures

2.1 扰动位置编码

在 Transformer 架构中,位置编码被 PE(positional encoding)用于向输入序列注入相应的位置信息,从而增强模型对序列顺序的感知能力。尽管大多数研究者倾向于采用传统位置编码来处理有序序列,但这种方法存在一个潜在缺陷,其对位置的表示是静态的,且在训练期间保持不变。这种固定性可能导致模型对位置信息过度依赖,并在处理超出训练时所见长度的序列时引发问题。传统位置编码的计算方式为:

$$PE(pos, 2i) = \sin\left(\frac{pos}{10000^{2i/d_{model}}}\right) \quad (1)$$

$$PE(pos, 2i + 1) = \cos\left(\frac{pos}{10000^{2i/d_{model}}}\right) \quad (2)$$

式中: d_{model} 为输入序列的维度;pos 为输入序列位置信息。

这种编码方式的设计初衷是为了实现位置信息的灵活嵌入,使其不依赖于特定输入长度,从而能够

应用于任意长度的序列。传统位置编码的固定模式可以避免变长序列的重复计算适应不同长度,但对位置信息的强依赖会限制模型的泛化能力,模型可能会过度依赖于这些固定的位置信息。当模型面对训练时未见过的序列长度时,可能导致性能下降,甚至失效。

为了解决传统位置编码在处理未见过的序列长度时泛化能力差的问题,本文提出了一种改进方法,即在传统位置编码的基础上加上随机高斯噪声,通过向位置编码中添加这种噪声,打破其固定性,使模型在训练过程中能够更好地适应不同位置信息。

扰动位置编码不仅提高了模型的泛化能力,还使得位置的表示变得更加灵活。由于噪声的随机性,每次训练时位置编码都会略有变化,这迫使模型不再过度依赖于固定的位置信息。因此,当模型面对训练时未见过的序列长度时,能够更好地利用已学到的位置信息来处理新的输入。

SNR 是评估信号质量的一个重要指标,被定义为正常信号功率与噪声功率之间的比值,通常以分贝(dB)为单位来衡量。较高的信噪比意味着信号中的有用信息相对于噪声更为突出,从而更容易被准确提取和处理。信噪比表示为:

$$\text{SNR} = 10 \lg \frac{\sum_{t=0}^{N-1} x^2(t)}{\sum_{t=0}^{N-1} n^2(t)} \quad (3)$$

高斯白噪声是具有特定统计特性的噪声模型,它在频谱上是均匀的,且其幅度分布服从高斯分布。生成的随机高斯白噪声表示为:

$$\text{noise} = \text{random}(N) \sqrt{\frac{\sum x_i^2}{N} \times 10^{-\frac{\text{SNR}}{10}}} \quad (4)$$

这种噪声模型在理论和实验中都得到了广泛应用,能够很好地模拟现实世界中许多实际干扰的统计特性。扰动位置编码的计算方式为:

$$\text{PE}(\text{pos}, 2i) = \sin\left(\frac{\text{pos}}{10000^{2i/d_{\text{model}}}}\right) + \text{noise} \quad (5)$$

$$\text{PE}(\text{pos}, 2i+1) = \cos\left(\frac{\text{pos}}{10000^{2i/d_{\text{model}}}}\right) + \text{noise} \quad (6)$$

本文旨在通过将随机高斯白噪声引入到位置编码中,解决传统位置编码泛化能力差的问题。它有助于防止模型过度依赖于训练数据中的固定位置信息,从而提高模型在处理未知长度序列时的泛化能力。同时,由于高斯白噪声具有随机性,它可以使模型在训练过程中不断适应各种位置变化,进一步增强模型的灵活性和鲁棒性。

2.2 低秩注意力机制

Transformer 模型以其独特的架构设计和多头注意力机制,在如自然语言处理、语音识别和图像处理等众多领域取得了显著成功。特别是多头注意力机制,允许模型同时关注来自不同位置的信息,从而提高了模型的表达能力和对复杂数据的处理能力。然而,对于较长的时间序列数据,Transformer 模型的训练代价相对较高。这主要是由于多头注意力机制的计算复杂度与输入序列长度的平方成正比,即 $O(n^2)$ 。当处理长序列时,这种计算复杂度的增长会导致训练时间显著增加,从而限制了 Transformer 模型在处理长序列任务中的应用。为了降低 Transformer 模型的训练成本并提升其效率,本文对 LRformer 模型中的多头注意力机制进行了改进,在保持模型性能不变的基础上,降低模型的计算复杂度,进而实现模型的轻量化。

图 3(a)和图 3(b)中的灰色框图分别描绘了多头注意力机制和低秩注意力机制的结构框架。在传统的多头注意力机制中,输入的查询(Q)、键(K)、

值(V)会首先经过线性层的投影处理。随后,这些经过投影的元素会采用点积自注意力机制进一步处理。即输入的 Q、K、V 在经过线性变换后,通过计算 Q 和 K 的点积来衡量它们之间的相似度,再经过 softmax 函数归一化得到权重分布,最后,将这个权重分布应用于 V,从而得到加权后的输出结果。

每个自注意力机制的输出表示为:

$$\text{head} = \text{Attention}(Q \cdot W^Q, K \cdot W^K, V \cdot W^V) = \text{softmax}\left(\frac{Q \cdot W^Q (K \cdot W^K)^T}{\sqrt{d_k}}\right) V \cdot W^V \quad (7)$$

多头注意力机制的输出结果表示为:

$$\text{MultiHead} = \text{Concat}(\text{head}_1, \dots, \text{head}_k) W^Q \quad (8)$$

本文通过改进线性注意力机制^[24],使其在时间序列分类任务中具有更高的适用性,相较于传统的多头注意力机制,低秩注意力机制在计算方面呈现出更为高效的特性。其核心思想在于通过引入低秩分解,有效降低注意力矩阵的秩,进而显著减少计算量与存储需求。本文所提出的低秩注意力机制实现过程如下:首先,对输入的查询(Q)、键(K)、值(V)通过线性层处理,降低 K、V 的维度以适配低秩空间。接着,利用低秩分解技术,将变换后的 K、V 投影至 1 个低秩子空间中。在这个低秩子空间内,计算注意力权重并生成加权的中间表示。最后,通过线性变换将中间表示映射回原始空间,得到最终的输出结果。低秩注意力机制的计算方式为:

$$\text{head} = \text{Attention}(Q \cdot W^Q, MK \cdot W^K, NV \cdot W^V) = \text{softmax}\left(\frac{Q \cdot W^Q (MK \cdot W^K)^T}{\sqrt{d_k}}\right) NV \cdot W^V = ENV \cdot W^V \quad (9)$$

在传统的多头注意力机制中, W^Q 、 W^K 、 W^V 矩阵都是通过模型训练学习到的,且它们都具有相同的维度 $n \times d_{\text{model}}$,其中 n 为序列长度, d 为特征维度。本文在低秩注意力机制中引入映射矩阵 M 和 N ,它们都是 $k \times n$ 的矩阵,其中 k 为低秩空间的维度。通过 softmax 函数得到映射矩阵 E ,其维度为 $n \times k$,而 $NV \cdot W^V$ 为 $k \times d$ 的矩阵,所以低秩多头注意力机制的空间复杂度为 $O(kn + 2kd)$,远低于传统的多头注意力机制,当映射维度 k 的值非常小时,可以显著降低训练的代价。此外,低秩注意力机制在计算过程中会降低矩阵的秩,计算量得到显著减少,这使得模型能够在保持性能的同时,进行更高效地训练和推理。

2.3 ConvFFN

本文引入了一种轻量化的 ConvFFN,该网络结合了卷积神经网络(convolutional neural networks, CNN)的特征提取能力和前馈神经网络 FFN 的灵

活性^[25]。ConvFFN 能够通过卷积操作捕捉输入数据的局部特征,并通过前馈神经网络将这些特征输出,以实现高效的特征转换和信息传递。

具体来说,ConvFFN 由多个卷积层构成,包括 DWConv 和 1×1 卷积层,对输入序列进行卷积运算,生成包含空间层次信息的特征图。随后,这些特征图经过非线性激活函数(ReLU),以增加模型的表达能力。此外,本文还加入 BatchNorm 来降低特征图的维度,从而减少计算量和过拟合的风险。

与传统的前馈神经网络相似,ConvFFN 使用等效的 1×1 卷积层代替了全连接层,同时 ConvFFN 通过卷积操作在特征提取过程中保留了输入数据的空间结构信息。此外,还加入了 Skip-Connection,通过添加从输入到输出的直接连接路径,有助于网络学习恒等映射并缓解梯度消失问题,从而加速训练过程并提高模型的性能。

3 实验分析

3.1 实验设置

3.1.1 实验数据及实验环境

本研究采用的数据集源自仿真实验,共计 10 500 个样本。为确保研究的准确性和可靠性,将数据集划分为训练集和测试集,其中,训练集包含 8 400 个样本,测试集包含 2 100 个样本。每个样本均包含图 2 所示的 12 个特征,并附有构建连续 12 帧时间步长的时间序列数据。

本文所有实验均在特定的计算环境中进行,具体配置如下:编程语言基于 Python 3.9,深度学习框架采用 PyTorch 2.1.0,并利用 CUDA 11.8 进行 GPU 加速。实验硬件包括 Intel © Xeon(R) Silver 4110 CPU,主频为 2.10 GHz,配备 Nvidia A100 GPU 以及 128 G 内存。

3.1.2 模型性能评估指标

在本文中,空中目标意图识别任务被当作时间序列分类任务。为了全面评估 LRformer 模型的性能表现,本文选取了时间序列分类中常用的几项评价指标,包括准确率(Accuracy)、F1 分数(F1-Score)、精确率(Precision)、召回率(Recall)以及损失值(Loss)。

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (10)$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (11)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (12)$$

式中:TP 为实际为正且预测为正的样本数;TN 为实际为负且预测为负的样本数;FP 为实际为负但预测为正的样本数;FN 为实际为正但预测为负的样本数。

$$\text{F1-Score} = \frac{2 \times (\text{Precision} \times \text{Recall})}{\text{Precision} + \text{Recall}} \quad (13)$$

F1 分数是精确率和召回率的调和平均数,用于综合评价模型的性能。

$$\text{Loss} = - \sum p_i \times \log(q_i) \quad (14)$$

式中: p_i 为真实标签; q_i 为模型预测标签的概率。

3.1.3 实验参数设置

在实验过程中,LRformer 模型需要人工调试参数,不同的参数配置对实验结果造成很大影响。本文实验参数配置如表 1 所示。

表 1 LRformer 模型参数配置

Tab. 1 Parameter configuration of LRformer model

参数	值
低秩注意力机制头数(head)	8
编码器堆叠层数(n)	6
隐藏层层数(d_{model})	512
映射层层数(k)	256
学习率	0.000 1
批次大小(Batch_size)	32
优化器	Adam
信噪比(SNR)	40
训练轮数(Epoch)	100

3.2 对比实验分析

为了更严谨地评估 LRformer 模型性能,本文选取了近年来在空中目标意图识别领域表现优异的多种模型作为对比基准,包括基于传统方法的 FCN-GRU^[17]、时间卷积神经网络(temporal convolutional network, TCN)^[20]、BP-GRU^[26]以及基于 Transformer 架构的原始 Transformer^[27]、informer^[28]、Crossformer^[29],结果如表 2 和图 4 所示。

表 2 对比实验结果

Tab. 2 Comparative experimental results

模型	Accuracy/ Precision/ Recall/			F1-Score	Loss
	%	%	%		
LRformer	98.86	98.68	97.89	98.22	0.136
FCN-GRU	98.57	98.33	97.62	97.58	0.155
TCN	97.73	97.52	96.97	97.05	0.221
BP-GRU	97.43	97.18	96.88	96.76	0.237
Transformer	96.61	96.26	95.72	95.62	0.406
informer	97.86	97.77	97.05	97.11	0.211
Crossformer	98.68	98.24	97.75	97.88	0.147

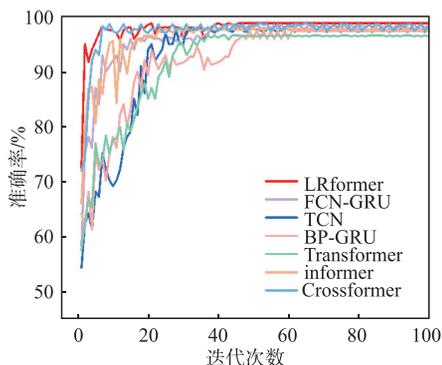


图 4 测试集对比实验结果

Fig. 4 Test set comparison experiment results

根据表 2 和图 4 的结果可以清晰看到,本文所提出的模型在空中目标意图识别任务中展现出了卓越的性能。具体而言,LRformer 模型以高达 98.86% 的准确率脱颖而出,成为所选对比模型中表现最佳者。此外,LRformer 模型在精确率、召回率以及 F1 分数等多个评估指标上同样有着出色的表现,且损失值维持在较低水平。上述指标结果充分证明了 LRformer 模型在空中目标意图识别领域的有效性和优越性。

为了进一步分析 LRformer 的有效性,本文通过混淆矩阵来观测 LRformer 模型的预测意图和真实意图之间的关系。文献[17]指出,由于空中目标的攻击、佯攻、警戒和监察意图在特征上具有较高的相似性和较强的欺骗性,因此在识别过程中可能会出现部分混淆。如图 5 所示,进攻意图、佯攻意图和突防意图之间存在一定的误判情况,同时监察意图和电子干扰意图也可能发生相互识别。然而,从整体识别结果来看,各类意图的识别准确率均较高,显示出 LRformer 模型的有效性。

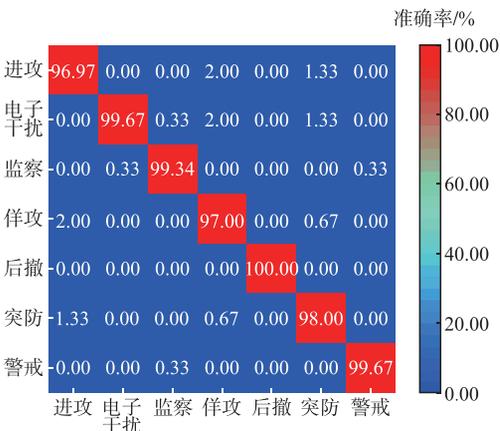


图 5 LRformer 模型混淆矩阵结果

Fig. 5 Confusion matrix results of LRformer model

3.3 模型参数量及计算复杂度分析

针对空中目标意图识别这类实时性要求严谨的任务场景,模型不仅要有高精度识别能力,还要有快

速推理能力。为验证 LRformer 模型在轻量化方面的优势,本研究通过实验测算了 LRformer 及其对比模型的参数量与计算复杂度,具体结果见表 3。

表 3 模型参数量及计算复杂度结果

Tab. 3 Number of model parameters and computational complexity results

模型	参数量	计算复杂度	训练时长/s
LRformer	1.05 × 10⁶	2.12 × 10⁶	420
FCN-GRU	4.33 × 10 ⁶	4.51 × 10 ⁶	513
TCN	7.78 × 10 ⁶	8.62 × 10 ⁶	624
BP-GRU	5.52 × 10 ⁶	5.86 × 10 ⁶	584
Transformer	10.97 × 10 ⁶	14.25 × 10 ⁶	785
informer	8.58 × 10 ⁶	12.17 × 10 ⁶	662
Crossformer	13.92 × 10 ⁶	1.4 × 10 ⁹	1 186

注:加粗表示最优结果。

表 3 实验结果清晰地表明 LRformer 在参数量和计算复杂度上均表现出显著低于对比模型的优势,其中,LRformer 的参数量仅为 1.05 × 10⁶,计算复杂度也低至 2.12 × 10⁶。通过对比分析,可以看到 LRformer 在性能优化和资源消耗控制方面的突出表现。

3.4 消融实验

为验证 LRformer 各组成模块的有效性,本文对 LRformer 的扰动位置编码、低秩注意力机制以及 ConvFFN 3 个关键组成模块进行了消融实验。将 LRformer 模型中的组成模块替换为 Transformer 原始的组成模块,以进一步分析这些模块对模型性能的影响,结果如表 4 所示。

表 4 消融实验结果

Tab. 4 Results of the ablation experiments

LRformer 组成模块			Accuracy/ %	参数量	计算 复杂度
扰动 位置编码	低秩注意力 机制	ConvFFN			
✓	✓	✓	97.26	1.05 × 10 ⁶	2.12 × 10 ⁶
	✓⊙	✓⊙	97.15	1.05 × 10 ⁶	2.12 × 10 ⁶
✓		✓⊙	98.42	3.51 × 10 ⁶	4.89 × 10 ⁶
✓	✓⊙		97.58	2.76 × 10 ⁶	3.43 × 10 ⁶
✓	✓⊙	✓⊙	98.86	1.05 × 10 ⁶	2.12 × 10 ⁶

注:✓⊙表示进行 Reverse 操作。

表 4 清晰地展示了 LRformer 模型各组成模块的作用及其替换对模型性能、参数量和计算复杂度的影响。具体来说,当 LRformer 模型的低秩注意力机制和 ConvFFN 模块未进行 Reverse 操作时,意图识别准确为 97.26%,参数量和计算复杂度分别

为 1.05×10^6 和 2.12×10^6 。当扰动位置编码被替换为原始位置编码时,模型的准确率达到 97.15%,而参数量和计算复杂度并未发生变化。这表明,扰动位置编码对模型性能具有一定的影响,但在参数量和计算复杂度方面并无显著差异。另一方面,本文用多头注意力机制替换低秩注意力机制时,模型的准确率达到 98.42%,但与此同时,参数量和计算复杂度也分别显著上升至 3.51×10^6 和 4.89×10^6 。这一结果说明,多头注意力机制在提高模型性能的同时,也带来了更高的参数量和计算复杂度。此外,本文将 ConvFFN 替换为原始 FFN 时,模型的准确率为 97.58%,而参数量和计算复杂度则分别上升至 2.76×10^6 和 3.43×10^6 。这表明,FFN 同样对模型性能产生影响,并且在参数量和计算复杂度方面也存在差异。综上所述,LRformer 模型的各组成模块对模型的性能、参数量和计算复杂度均有一定影响。

4 结语

本文针对空中目标意图识别中模型架构复杂、识别效率不高的问题,在 Transformer 模型的基础上进行了改进。首先,通过引入 Reverse 操作,优化了模型对时间序列分类任务的适应性。其次,对 LRformer 模型进行了轻量化设计,同时改进了注意力机制和前馈神经网络模块,以提升模型的识别速度和效率。最后,通过对比实验、消融实验以及模型复杂度分析,验证了改进后的 LRformer 模型在识别空中目标意图方面的有效性。

经过深入的理论研究和实验验证,发现空中目标意图识别问题仍存在若干挑战。在未来的研究工作中,将重点关注并解决以下问题,以期推动该领域的进一步发展。近年来,深度学习技术在空中目标意图识别领域取得了显著进展,为解决该问题提供了新方案。然而,这些方法往往缺乏自适应调整能力,难以适应动态变化的场景。因此,在复杂环境下,其表现往往难以保证。为提升空中目标意图识别的准确性和鲁棒性,未来研究需要更加关注模型的自适应能力,使其能够更好应对各种复杂场景的挑战。在空中目标意图识别任务中,实时性要求至关重要。因此,模型不仅需要具备高精度识别能力,还必须拥有快速推理能力。然而,传统方法往往难以在这两者之间达到平衡。为满足实际应用中实时性需求,需要对模型进行精心设计,在确保识别准确率的同时,降低模型的计算复杂度和推理时间。

参考文献

- [1] 王海旺,史红权,赵晓哲. 目标意图识别方法综述 [C]//2020 中国系统仿真与虚拟现实技术高层论坛论文集,2020:189-191.
WANG H W,SHI H Q,ZHAO X Z. A Summary of Target Intention Identification Methods [C]// Proceedings of the 2020 China High-Level Forum on System Simulation and Virtual Reality Technology, 2020:189-191. (in Chinese)
- [2] 张晨浩,周焰,蔡益朝,等. 空中目标作战意图识别研究综述[J]. 现代防御技术,2024,52(4):1-15.
ZHANG C H,ZHOU Y,CAI Y C, et al. A Review of Air Target Operational Intention Recognition Research[J]. Modern Defence Technology,2024,52(4):1-15. (in Chinese)
- [3] HUANG J,LIU W,ZHAO Y J. Intuitionistic Cloud Reasoning and Its Application in Aerial Target Intention Analysis[J]. Operations Research and Fuzziology,2014,4(4):60-69.
- [4] 和钰,常雷雷,姜江,等. 基于置信规则库的防空目标意图识别方法[J]. 火力与指挥控制,2017,42(9):7-12.
HE Y,CHANG L L,JIANG J, et al. Intension Identification in Air Defense Based on Belief Rule Base Expert System under Expert Guidance[J]. Fire Control & Command Control,2017,42(9):7-12. (in Chinese)
- [5] 陈黎,李芳芳,邹长虹. 基于动态贝叶斯网络和模板匹配的空中目标意图识别[J]. 现代防御技术,2023,51(2):62-70.
CHEN L,LI F F,ZOU C H. Intension Recognition of Air-Defense Target Based on Dynamic Bayesian Network and Template Matching [J]. Modern Defence Technology,2023,51(2):62-70. (in Chinese)
- [6] 李乐民,宋亚飞,王鹏,等. 一种基于全卷积神经网络的空中目标战术意图识别模型[J]. 空军工程大学学报,2024,25(5):98-106.
LI L M,SONG Y F,WANG P, et al. A Full Convolutional Neural Network-Based Tactical Intent Recognition Model for Airborne Targets[J]. Journal of Air Force Engineering University,2024,25(5):98-106. (in Chinese)
- [7] 徐建平,张立凡,韩德强. 基于模糊推理的空中目标意图识别[J]. 指挥信息系统与技术,2020,11(3):44-48.
XU J P,ZHANG L F,HAN D Q. Air Target Intention Recognition Based on Fuzzy Inference[J]. Command Information System and Technology,2020,11(3):44-48. (in Chinese)

- [8] 杨卓,师鹏,周韬,等. 基于模糊推理的空间非合作目标意图识别方法[J/OL]. 北京航空航天大学学报,1-18. (2024-01-12) [2024-03-25]. <https://doi.org/10.13700/j. bh. 1001-5965. 2023. 0581>.
YANG Z, SHI P, ZHOU T, et al. Intention Recognition Method of Space Non-Cooperative Target Based on Fuzzy Reasoning[J]. Journal of Beijing University of Aeronautics and Astronautics, 1-18. (2024-01-12) [2024-03-25]. <https://doi.org/10.13700/j. bh. 1001-5965. 2023. 0581>. (in Chinese)
- [9] 孙亮,于雷,邹德鹏. Dempster-Shafer 证据理论在目标意图预测中的应用[J]. 电光与控制,2008,15(3): 33-36.
SUN L, YU L, ZOU D P. Application of Dempster-Shafer Evidence Theory in Target Intention Prediction [J]. Electronics Optics & Control, 2008, 15(3): 33-36. (in Chinese)
- [10] 王小平,夏命辉,林秦颖,等. 接敌前基于 D-S 理论的空战意图预测[J]. 火力与指挥控制,2016,41(9): 185-188.
WANG X P, XIA M H, LIN Q Y, et al. Combat Intent Forecast Based on D-S Evidence Theory before Contacting the Enemy[J]. Fire Control & Command Control, 2016, 41(9): 185-188. (in Chinese)
- [11] 张瑜,邓鑫洋,李明焜,等. 基于证据网络因果分析的空战意图识别[J]. 航空学报,2022,43(S1): 143-56.
ZHANG Y, DENG X Y, LI M D, et al. Air Target Intention Recognition Based on Evidence-Network Causal Analysis[J]. Acta Aeronautica et Astronautica Sinica, 2022, 43(S1): 143-56. (in Chinese)
- [12] ZHANG Y, HUANG F H, DENG X Y, et al. Air Target Intention Recognition and Causal Effect Analysis Combining Uncertainty Information Reasoning and Potential Outcome Framework[J]. Chinese Journal of Aeronautics, 2024, 37(1): 287-299.
- [13] 朱波,方立恭,张小东. 基于贝叶斯网络的空战意图识别方法[J]. 现代防御技术,2012,40(2): 109-113.
ZHU B, FANG L G, ZHANG X D. Intention Assessment to Aerial Target Based on Bayesian Network [J]. Modern Defence Technology, 2012, 40(2): 109-113. (in Chinese)
- [14] 马静. 贝叶斯网络的战场作战意图评估方法[J]. 西安工业大学学报,2010,30(4): 397-401.
MA J. Assessment of Operational Intention in Battlefield Based on Bayesian Network[J]. Journal of Xi'an Technological University, 2010, 30(4): 397-401. (in Chinese)
- [15] 钱钊,刘钦,鹿瑶,等. 基于长短时神经网络的目标意图识别[J]. 太赫兹科学与电子信息学报,2022,20(11): 1156-1162.
QIAN Z, LIU Q, LU Y, et al. Identification of Target's Combat Intention Based on Long Short Term Memory Network[J]. Journal of Terahertz Science and Electronic Information Technology, 2022, 20(11): 1156-1162. (in Chinese)
- [16] 李颖,武君胜,李伟刚,等. 一种识别作战意图的层次聚合模型[J]. 西北工业大学学报,2023,41(2): 400-408.
LI Y, WU J S, LI W G, et al. A Hierarchical Aggregation Model for Combat Intention Recognition [J]. Journal of Northwestern Polytechnical University, 2023, 41(2): 400-408. (in Chinese)
- [17] 丁鹏,宋亚飞. 代价敏感的空中目标意图识别方法[J]. 航空学报,2023,44(24): 328551.
DING P, SONG Y F. A Cost-Sensitive Method for Aerial Target Intention Recognition[J]. Acta Aeronautica et Astronautica Sinica, 2023, 44(24): 328551. (in Chinese)
- [18] 宋晓程,冯舒婷,姜涛,等. 基于 PACA 的复杂空中目标战术意图识别方法[J]. 现代防御技术,2024,52(3): 48-54.
SONG X C, FENG S T, JIANG T, et al. Tactical Intention Recognition of Complex Air Targets Based on PACA[J]. Modern Defence Technology, 2024, 52(3): 48-54. (in Chinese)
- [19] 潘明,郑景嵩,李金亮,等. 面向空战对抗行为意图分析的小样本学习方法[J]. 哈尔滨理工大学学报,2024,29(4): 50-58.
PAN M, ZHENG J S, LI J L, et al. A Few-Shot Learning Method for Intent Analysis of Air Combat Confrontation Behaviors[J]. Journal of Harbin University of Science and Technology, 2024, 29(4): 50-58. (in Chinese)
- [20] 赵亮,孙鹏,张杰勇,等. 难分类样本快速空中目标意图识别方法[J]. 空军工程大学学报,2024,25(1): 76-82.
ZHAO L, SUN P, ZHANG J Y, et al. A Fast Aerial Targets Intention Recognition Method under Imbalanced Hard-Sample[J]. Journal of Air Force Engineering University, 2024, 25(1): 76-82. (in Chinese)
- [21] 崇元,李加祥. 基于作战知识的海战场对空防御深层态势分析[J]. 现代防御技术,2016,44(1): 112-117.
CHONG Y, LI J X. Situation Analysis Hierarchical on Naval Battlefield for Air Defense Based on Operational Knowledge[J]. Modern Defence Technology, 2016, 44(1): 112-117. (in Chinese)
- [22] 陈浩,任卿龙,滑艺,等. 基于模糊神经网络的海面目标战术意图识别[J]. 系统工程与电子技术,2016,38(8): 1847-1853.
CHEN H, REN Q L, HUA Y, et al. Fuzzy Neural

