

# 一种基于 GRU 的空中目标作战意图预测方法

雷蕾<sup>1</sup>, 滕飞<sup>2</sup>, 权文<sup>3</sup>, 倪鹏<sup>4</sup>

(1. 空军工程大学信息与导航学院, 西安, 710077; 2. 93525 部队, 西藏日喀则, 857060;  
3. 空军工程大学空管领航学院, 西安, 710051; 4. 复杂航空系统仿真重点实验室, 北京, 100076)

**摘要** 由于实际空战中目标作战意图是由一系列战术动作实现的, 因此目标状态呈现时序、动态的变化特征。传统作战意图识别方法仅依靠单一时刻进行推理, 方法不够科学有效, 并且没有提前预测敌方意图的效果。在门控循环单元(GRU)的基础上引入双向传播机制和注意力机制, 提出一种空中目标作战意图预测方法。通过分层的方法构建空战意图特征集, 编码生成数值型时序特征, 并将领域专家知识经验封装成标签; 运用 BiGRU 网络对空战特征进行深层次学习, 并利用注意力机制自适应分配特征权重, 以提升空中目标作战意图识别准确度。为实现对目标意图的提前预测, 在意图识别之前引入空战特征预测模块, 建立预测特征与作战意图类型之间的映射关系仿真, 实验表明, 所提模型能在 89.7% 意图识别准确度的基础上提前一个采样点预测出敌方空中目标作战意图, 在提升意图识别实时性方面具有显著意义。

**关键词** 意图预测; 门控循环单元; 注意力机制; 空中目标

**DOI** 10.3969/j.issn.2097-1915.2025.02.012

**中图分类号** TJ760 **文献标志码** A **文章编号** 2097-1915(2025)02-0100-12

## A Prediction of Air Target Combat Intention Based on GRU

LEI Lei<sup>1</sup>, TENG Fei<sup>2</sup>, QUAN Wen<sup>3</sup>, NI Peng<sup>4</sup>

(1. Information and Navigation School, Air Force Engineering University, Xi'an 710077, China; 2. Unit 93525, Xigaze 857060, Xizang, China; 3. Air Traffic Control and Navigation School, Air Force Engineering University, Xi'an 710051, China; 4. Science and Technology on Complex Aviation Systems Simulation Laboratory, Beijing 100076, China)

**Abstract** In actual air combat, the target combat intention is realized by a series of tactical actions, and the target state is present to the characteristics of time sequence and dynamic change. The traditional operational intention recognition method only relies on a single moment of reasoning, which is not scientific and effective, and fails to predict the enemy's intention in advance. Therefore, the bi-directional propagation mechanism and an attention mechanism are introduced on the basis of the gated recurrent unit (GRU), and a method for predicting the combat intention of aerial targets is proposed. This method is to construct the air combat intention feature set through a layered method, encode to generate numerical time series features, and encapsulate domain expert knowledge and experience into labels. The BiGRU network is used for in-depth learning of air combat features, and the attention mechanism is used to adaptively as-

收稿日期: 2024-03-07

基金项目: 国家自然科学基金(61806219); 陕西省高校科协青年人才托举计划(20220106)

作者简介: 雷蕾(1988-), 女, 四川南充人, 讲师, 博士, 研究方向为智能信息处理。E-mail: wendyandpaopao@163.com

**引用格式:** 雷蕾, 滕飞, 权文, 等. 一种基于 GRU 的空中目标作战意图预测方法[J]. 空军工程大学学报, 2025, 26(2): 100-111. LEI Lei, TENG Fei, QUAN Wen, et al. A Prediction of Air Target Combat Intention Based on GRU[J]. Journal of Air Force Engineering University, 2025, 26(2): 100-111.

sign feature weights to improve the accuracy of air target combat intention recognition. In order to realize the advance prediction of the target intention, the air combat feature prediction module is introduced before the intention recognition, and the mapping relationship between the predicted feature and the combat intention type is established. The simulation experiments show that the proposed model can predict the combat intention of the enemy's air target by one sampling point in advance based on the accuracy of 89.7% intention recognition, and has obviously significance in improving the real-time performance of intention recognition.

**Key words** intention prediction;gated recurrent unit;attention mechanism;aerial target

2019 年底,美国智库从大国对抗的需求出发,提出了“决策中心战”的概念。“决策中心战”的制胜机理是保持己方决策优势,同时使敌方处于决策劣势,既要求己方的作战决策迅速而正确,同时想办法降低敌方决策速度和质量。“决策中心战”不着眼于摧毁对手力量,而是侧重于比对手做出更快更好的决策,给对手造成多重困境,使其无法实现目标。由此可见,战场认知与决策速度已经成为战争胜负的决定因素,谁能够更快地处理战场信息、理解态势、实施决策并执行打击,谁就能赢得主动。因此,我们必须加速从“掌控信息优势”向“掌控决策优势”的转变,以此作为军事智能化转型的重要牵引,探索从战场数据向态势信息、决策知识乃至指挥智慧的演变进程,不断强化以战场认知为基础的指挥决策能力。

目标意图识别是战场态势感知的核心内容,一直以来都是各级指挥员密切关注的重点。意图识别是从信息域向认知域过渡的关键,是指挥决策的基本依据,也是战场认知和智能决策的前提和基础。对于防空反导作战这一空天领域的激烈对抗而言,对空中目标作战意图的准确识别,是实现从态势信息优势向指挥决策优势跃升的前提和基础,也是一直以来制约防空反导作战指挥决策的瓶颈<sup>[1-2]</sup>。

目前对目标作战意图识别的研究主要借助于证据理论<sup>[3]</sup>、模板匹配<sup>[4]</sup>、专家系统<sup>[5]</sup>、贝叶斯网络<sup>[6]</sup>和神经网络<sup>[7]</sup>等方法。其中,基于深度学习的意图识别方法备受关注<sup>[8-10]</sup>,在战场目标作战意图识别领域取得了一定效果,但在时序特征学习和知识表示上存在不足。首先,目标作战意图是通过一系列战术动作实现的,因此目标的动态属性和战场环境会呈现出随时间不断变化的特征,并且敌方目标在执行作战行动时具有一定的隐蔽性和欺骗性,因此上述方法利用单一时刻特征信息来判断敌方目标作战意图是不够科学的。其次,上述方法需要显式地组织、抽象和描述军事专家的经验知识,知识表示和工程实现难度很大<sup>[9]</sup>。文献[9]针对以上方法的不足,提出基于长短期记忆(long short-term memo-

ry,LSTM)网络的战术意图智能识别模型,该模型的输入特征为连续 12 帧时序特征,能够有效克服通过单一时刻判断敌方目标作战意图的缺点,并且通过隐式的方法组织、抽象和描述军事专家的经验知识,使其知识表示和工程实现难度也不大。但其仅利用历史时刻信息来对当前信息作出推理,无法有效利用未来时刻信息。文献[11]提出了一种基于 GRU-FCN 的意图识别模型,并针对误判代价问题,创新性地设计了空中目标意图识别的代价敏感(cost-sensitive air target combat intention recognition, CAIR)改进方法,从而优化了模型的识别性能。文献[12]针对空中目标群组意图识别难题,提出基于滑动窗口估计的时空卷积自注意力网络模型。该方法利用滑动窗口预处理特征数据,通过时空卷积网络提取时序特征,再结合自注意力机制捕捉关键信息。文献[13]提出了基于改进长短时记忆网络模型 RL-LSTM 的意图识别方法。该方法通过获取目标实时状态数据,以最后时刻状态为输入,利用 RL-LSTM 学习 7 种常见意图的特征信息,并通过 Softmax 分类器实现意图识别。以上方法皆是基于当前信息和历史信息对空中目标作战意图进行的识别,并没有充分利用对未来战场态势信息,依然是有“态”无“势”。

为实现对空中目标“想干什么”的提前预测,并充分利用未来时刻的预测信息,从而达到“态”与“势”的统一,本文提出了一种创新的基于 GRU 的空中目标作战意图智能预测模型。本模型由特征预测模块和意图识别模块两大部分构成。在意图识别模块中,以门控循环单元(gated recurrent unit, GRU)为基础框架,融合了双向(bidirectional)传播机制、注意力(attention)机制以及粒子群优化(particle swarm optimization, PSO)算法,共同构建了智能意图识别模型。相较于性能相近但结构更复杂的 LSTM,GRU 展现出更高的运算效率和较短的识别时间。而双向 GRU(BiGRU)的引入,使得模型能够同时参考历史与未来时刻的信息,为决策提供更

全面的数据支持。此外,采用 PSO 算法对 BiGRU 网络的参数进行优化,以寻找最佳的网络配置。注意力机制的加入,进一步强化了模型对关键意图信息的捕捉能力,从而有效提升了意图识别的精确度。特征预测模块则利用 BiGRU 网络深入分析收集到的多样化特征,对未来空中目标特征进行预测,并将这些预测特征作为输入传递给意图识别模块。通过这种方式,进一步建立了未来空中目标特征与敌方作战意图之间的映射关系。实验结果表明,本文所提出的模型能够在提前一个采样点的情况下,以高达 89.7% 的准确率成功预测敌方空中目标的作战意图。

## 1 空中目标作战意图识别问题描述

空中目标作战意图识别是指从动态、复杂的战场环境中,通过多个传感器获得实时数据,并通过对实时动态的数据进行分析,结合先验知识、相关作战领域专家经验等来推理敌方空中目标作战意图的过程,其过程如图 1 所示<sup>[6]</sup>。

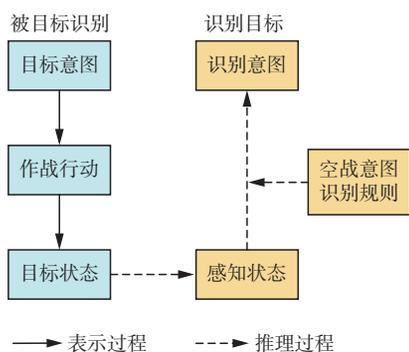


图 1 意图表示及推理过程

Fig. 1 Intention representation and reasoning process

空中目标意图识别是一种模式识别问题,可以描述为意图识别特征到空中目标作战意图类型的映射。定义向量  $\mathbf{V}(t)$  为  $t$  时刻空战实时特征信息,定义向量  $\mathbf{P}=(p_1, p_2, \dots, p_n)$  空中目标作战意图空间集,由于实际空战环境条件的复杂性、高对抗性以及欺骗性,依靠单一时刻检测的空战实时特征信息存在一定的欺骗性和片面性,故从连续时刻的空战特征信息中推断敌机的作战意图要远比从单一时刻空战特征信息推断其作战意图更具有准确性和科学性<sup>[1]</sup>。定义  $\mathbf{V}_m$  为  $t_1 \sim t_m$  连续  $m$  个时刻的特征集构成的时序特征集,从而确定作战意图空间集  $\mathbf{P}$  到时序特征集  $\mathbf{V}_m$  的映射函数:

$$\mathbf{P} = f(\mathbf{V}_m) = f(\mathbf{V}(t_1), \mathbf{V}(t_2), \dots, \mathbf{V}(t_m)) \quad (1)$$

可见,要实现对空中目标作战意图的准确识别

需要结合空战领域专家的专业军事知识以及作战经验等,通过对空战关键信息的提取、对比、分析、联想、推理等复杂的思维活动实现,很难利用单一的显式数学公式来建立起意图识别特征集  $\mathbf{V}_m$  到作战意图空间集  $\mathbf{P}$  之间的映射关系<sup>[9]</sup>。本文通过使用空中目标作战意图识别特征集训练 BiGRU-Attention 网络结构,隐式地建立起时序特征集与作战意图之间的映射关系。

### 1.1 空中目标作战意图空间集描述

目标作战意图空间集针对不同的作战形式、不同敌方实体和不同的想定背景,所对应的目标作战意图集存在差异。因此需要根据相对应的作战背景、敌方目标的具备属性和可能执行的作战任务来定义敌方目标的作战意图空间集<sup>[10]</sup>。文献[14]根据水下目标潜在威胁建立的目标意图空间集为{规避,巡逻,攻击}。文献[15]针对敌方单组海上舰船编队建立作战意图空间集为{撤退,掩护,攻击,侦察}。文献[16]定义空中目标的作战意图空间集为{侦察,监视,攻击,突防}。本文以无人机近距离交战为研究对象,建立敌方目标的作战意图空间集包括{佯攻,监视,电子干扰,突防,攻击,撤退,侦察}7种意图类型。

在确定敌方作战意图空间集后,如何将人的认知模型转换成智能模型能够训练的标签,并与作战意图空间集中的意图类型相对应,是将本文提出智能识别模型应用于作战意图识别的关键<sup>[17]</sup>。因此,可以将空战领域专家的经验封装成标签来训练本文的智能识别模型。针对本文确立的敌方目标作战意图空间集中的7种意图类型,分别设置{0,1,2,3,4,5,6}共7种标签值,相应的作战意图类型编码与模型解析机制如图2所示。例如,若本文所提模型输出的意图预测结果为5,则可以认为敌方目标对我方目标的作战意图为撤退。故通过采用上述知识封装与模型解析能清晰、容易地描述人的经验知识,便于模型训练。

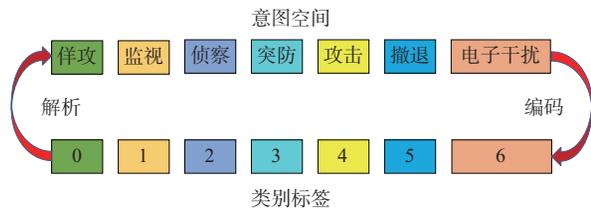


图 2 作战意图编码与模式解析

Fig. 2 Operational intention coding and mode analysis

### 1.2 空中目标作战意图识别特征集选取

敌方空中目标作战意图与敌方作战任务、双方

相互之间的威胁程度以及战术动作高度相关。本文依据领域专家的知识 and 上述三方面特点来选取与空中目标作战意图关系紧密的特征。

从作战任务角度分析,当敌方无人机执行某项任务时,其敌机的某些方面特征需要满足一定的条件。例如,在执行突防任务时分为高空突防和低空突防,相对应的高度为 10~11 km;歼击机在执行大速度接敌攻击时飞行速度一般为 735~1 470 km/h。空中目标雷达信号状态与作战任务也有一定的联系。例如,空中格斗时战机通常会开启对空雷达和电子干扰;执行侦察任务时通常会开启对海雷达和对空雷达。

从威胁程度角度分析,影响双方目标之间威胁程度大小的因素有很多,为方便实验数据采集,本文主要考虑敌我双方战机的速度、飞行加速度、距离、飞行高度、航向角、方位角<sup>[18]</sup>。如图 3 所示, $H_1$ 、 $H_2$  为敌我双方飞行高度; $V_1$ 、 $V_2$  为敌我双方飞行速度; $D$  为双方距离; $\Psi$  为航向角; $\varphi$  为方位角。

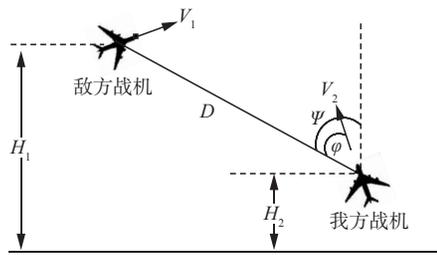


图 3 空战相对几何位置

Fig. 3 Relative geometric position of air combat

空战能力因子也是影响目标威胁程度大小的重要因素,对于战机的空战能力,依据文献<sup>[19]</sup>构建单机空战能力威胁函数:

$$C = \left[ \ln \varepsilon_1 + \ln(\varepsilon_2 + 1) + \ln(\sum \varepsilon_3 + 1) \right] \varepsilon_4 \varepsilon_5 \varepsilon_6 \varepsilon_7 \quad (2)$$

式中: $\varepsilon_1 \sim \varepsilon_7$  分别为战机机动性能、机载武器性能、机载探测能力、战机操作性能、战机生存能力、战机作战航程以及电子信息对抗能力 7 个参数。空战能力威胁是战机固有属性,可以计算出一定时期内敌我双方各式战机的空战能力因子,将其保存到数据库中,并根据我方掌握情报随时进行数据库的更新<sup>[20]</sup>。

空中目标作战意图的实现与战机机动动作关系密切。常用的机动动作库有 2 种,分别是以典型空战战术飞机动作作为设计依据的“典型战术动作库”

和以空战基本操作动作为依据的“基本操纵动作库”。由于本文研究的是根据时序特征来对目标进行意图识别,通过连续 12 个时刻的目标特征为 1 次样本来进行目标作战意图识别,而“典型战术动作库”的控制算法求解复杂,动作的退出和转换时间节点难以确定。对于传统的“基本操纵动作库”<sup>[21]</sup>,该库的机动方式仅有 7 种,其组合出的机动动作不够丰富,并且都采用极限操纵方式,不符合实际空战情况。故本文采用改进后的“基本操纵动作库”,包括{左转,右转,加速前飞,匀速前飞,减速前飞,爬升,左爬升,右爬升,俯冲,左俯冲,右俯冲}共 11 种操纵动作<sup>[22]</sup>。

综上,本文的空中目标作战意图特征集为{敌机飞行高度,我机飞机高度,敌机飞行速度,我机飞行速度,敌机加速度,我机加速度,敌机空战能力因子,我机空战能力因子,航向角,双方距离,方位角,对空雷达状态,对海雷达状态,机动类型,干扰状态,受干扰状态}16 维特征向量,并且可以分为数值型和非数值型特征,如图 4 所示。

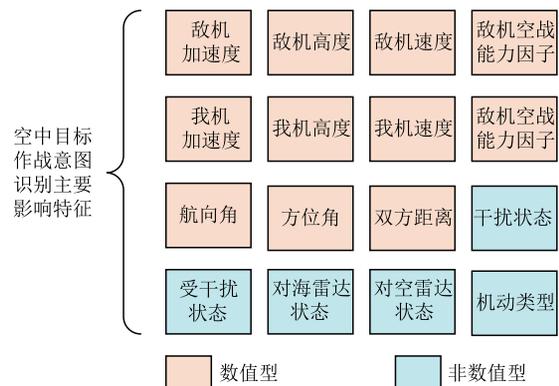


图 4 空中目标作战意图特征集

Fig. 4 Air target combat intention feature set

## 2 基于 GRU 的意图识别模型

本文提出的空中目标作战意图预测模型由特征预测模块和意图识别模块组成,如图 5 所示。基于 BiGRU 网络构建特征预测模块,将历史空中目标作战意图识别特征集  $V_m$  作为输入,利用全连接层的默认激活函数 Linear 输出得到预测特征集  $W_m$ 。将预测特征集  $W_m$  与历史空中目标作战意图识别特征集  $V_m$  组成时序特征数据输入以 BiGRU-Attention 网络构建的意图识别模块,利用 Softmax 函数计算出各意图类型的概率,输出最大概率意图类型标签,得到空中目标作战意图识别结果。

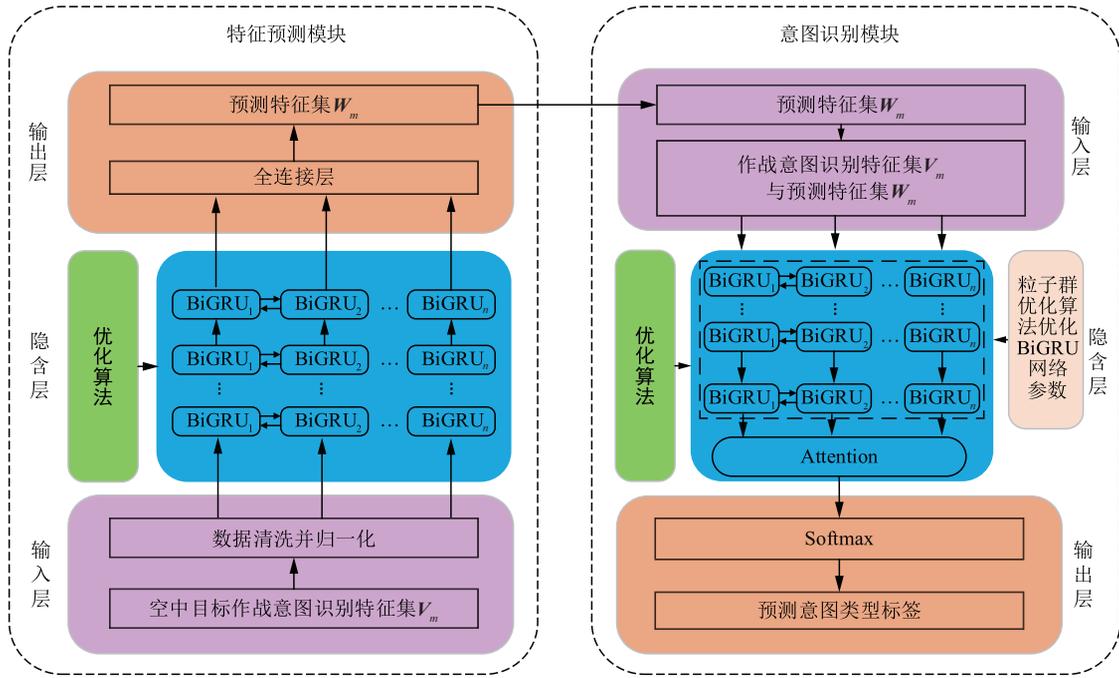


图5 模型整体结构

Fig. 5 Overall structure of the model

## 2.1 特征预测模块

BiGRU 特征预测模块共分为 3 部分:空中目标作战意图识别特征集输入层、隐含层、输出层。文献[23]已经证实各特征独立进行预测相对整体预测精度更高。因此,模块的输入节点为  $\text{input}=(8,1)$ ,其中,8 为步长;1 为特征维数;输出节点  $\text{output}=1$ ,表示输出特征维数为 1。

### 2.1.1 输入层

本文输入层主要是对采集的空中目标特征数据集进行预处理,即把数据集处理成 BiGRU 层能够直接接受并能处理的特征向量形式。空中目标特征向量化具体操作步骤如下:

**步骤 1** 读取采集数据集并进行数据清洗。

**步骤 2** 将非数值型空中目标特征数据编码化,对于干扰状态、受干扰状态、对空雷达状态和对海雷达状态 4 种属性编码为 1 和 0,0 表示关闭状态,1 表示打开状态。对于机动类型利用文献[24]提出的 Millier 9 级量化理论进行量化得到数值型数据,从而完成非数值型数据的编码化。

**步骤 3** 将数值型数据集通过时序数据标准归一化方式进行处理。数据归一化可以提高网络收敛速度、精度和防止模型梯度爆炸等。由于编码后的非数值型特征数据归一化后不会改变原始值。本文将 11 种数值型空中目标特征数据进行归一化。第  $i$  维特征数据表示为  $\mathbf{G}_i=[g_{i1}, g_{i2}, \dots, g_{ix}, \dots, g_{in}]$  ( $i=1,2,\dots,16$ ),其中  $n$  为数据总数,将第  $x$  个原始数据归一化到区间  $[0,1]$  的结果为  $g'_{ix}$ ,公式为:

$$g'_{ix} = \frac{g_{ix} - \min \mathbf{G}_i}{\max \mathbf{G}_i - \min \mathbf{G}_i} \quad (3)$$

式中:  $\max \mathbf{G}_i$  为第  $i$  维特征  $\mathbf{G}_i$  的最大值;  $\min \mathbf{G}_i$  为第  $i$  维特征  $\mathbf{G}_i$  的最小值。

**步骤 4** 将数据集按 8:2 划分成训练集和测试集。

**步骤 5** 按照以下方法构建训练样本和测试样本。采用单个特征依次预测的方法,以对敌机高度该空中目标作战意图特征进行预测为例。假设利用前  $n$  个时刻的敌机高度数据,预测第  $n+1$  时刻敌机高度  $H_{n+1}$ ,其函数映射关系为:

$$H_{n+1} = f(h_1, h_2, \dots, h_n) \quad (4)$$

式中:  $h_i, i \in (1, 2, \dots, n)$  为敌机在第  $i$  时刻的飞行高度。选取  $h_1 \sim h_n$  为第 1 组输入数据,标签为  $h_{n+1}$ ;以  $h_2 \sim h_{n+1}$  为输入数据,标签为  $h_{n+2}$ 。以此类推,组成如下所示的训练样本输入数据和训练样本标签,测试数据的构建方法与训练样本数据一致<sup>[25]</sup>。

$$\begin{bmatrix} h_1 & h_2 & \dots & h_m \\ h_2 & h_3 & \dots & h_{m+1} \\ \vdots & \vdots & & \vdots \\ h_n & h_{n+1} & \dots & h_{n+m} \end{bmatrix} \quad (5)$$

$$[h_{n+1} \quad h_{n+2} \quad \dots \quad h_{n+m+1}] \quad (6)$$

经过以上 5 个步骤,空中目标作战意图特征集  $\mathbf{V}_m$  就转换为隐含层,成为模型能够接受并处理的特征向量形式。

### 2.1.2 隐含层

门控循环单元(GRU)作为循环神经网络(re-

current neural network, RNN)的一个变体,也具有 RNN 相类似的递归结构,具有处理时间序列数据的“记忆”功能。同时,GRU 能够有效缓解 RNN 训练过程中可能出现的梯度消失和梯度爆炸问题,从而有效解决长期记忆问题。长短时记忆(LSTM)网络也是 RNN 的一个变体,和 GRU 在性能上相差无几,但 GRU 在结构上更加的简单,能够减少计算量,提高训练效率<sup>[26]</sup>。

GRU 的内部结构如图 6 所示。GRU 有 2 个输入,分别为上一时刻的输出状态  $h_{t-1}$  和当前时刻的输入序列值  $x_t$ ,输出为当前时刻的状态  $h_t$ 。其主要通过重置门  $r_t$  和更新门  $z_t$  来更新模型状态,重置门  $r_t$  控制遗忘历史状态信息的程度,使网络能够丢掉不重要的信息;更新门  $z_t$  控制前一时刻的状态信息被带入当前状态中的比重,帮助网络记忆长时的信息<sup>[27]</sup>。其内部计算式为:

$$\begin{cases} r_t = \sigma(W_r x_t + U_r h_{t-1}) \\ z_t = \sigma(W_z x_t + U_z h_{t-1}) \\ \tilde{h}_t = \tanh(W_{\tilde{h}} x_t + U_{\tilde{h}}(r_t \circ h_{t-1})) \\ h_t = (1 - z_t) \circ h_{t-1} + z_t \circ \tilde{h}_t \end{cases} \quad (7)$$

式中: $\sigma$  为 sigmoid 激活函数,其作用是将中间状态转换到 $[0,1]$ 范围内; $h_{t-1}$ 、 $h_t$  分别为  $t-1$  时刻和  $t$  时刻的输出状态; $x_t$  为  $t$  时刻的输入序列值; $\tilde{h}_t$  为候选输出状态; $W_r$ 、 $W_z$ 、 $W_{\tilde{h}}$ 、 $U_r$ 、 $U_z$ 、 $U_{\tilde{h}}$  为各部分相对应的权值系数矩阵; $\tanh$  为双曲正切函数; $\circ$  为矩阵的哈达马积。

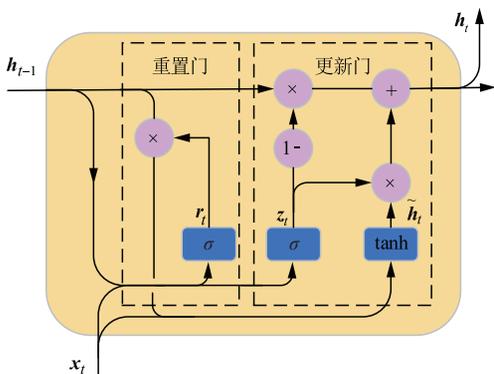


图 6 GRU 结构  
Fig. 6 GRU structure

传统的 GRU 结构通常沿序列传输方向进行单方向传播,它所获取的信息都是当前时刻之前的历史信息,从而导致忽略了未来的信息,而 BiGRU 结构是由前向的 GRU 和后向的 GRU 组成,具有能够捕获前后信息特征的能力,其模型结构如图 7 所示。

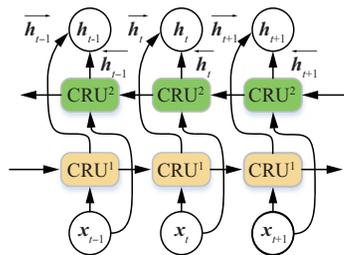


图 7 BiGRU 结构

Fig. 7 BiGRU structure

图中 GRU<sup>1</sup> 为前向 GRU;GRU<sup>2</sup> 为后向 GRU。可以看出 BiGRU 在  $t$  时刻的输出状态  $h_t$  可通过前向输出状态  $\vec{h}_t$  和后向输出状态  $\overleftarrow{h}_t$  2 部分求得,前向输出状态  $\vec{h}_t$  由  $t$  时刻的输入  $x_t$  和  $t-1$  时刻前向 GRU 的输出状态  $\vec{h}_{t-1}$  决定,后向输出状态  $\overleftarrow{h}_t$  由  $t$  时刻的输入  $x_t$  和  $t+1$  时刻的后向 GRU 输出状态  $\overleftarrow{h}_{t+1}$  决定。

2.1.3 输出层

将隐含层中 BiGRU 网络的输出  $h_t$  输入到输出层中的全连接层,利用 Linear 激活函数输出最后的预测特征值。

2.2 意图识别模块

意图识别模块共分为输入层、隐含层、输出层 3 部分,其中,隐含层由 BiGRU 层、Attention 层组成。网络的输入节点  $input=(12,16)$ ,输出节点  $output=7$ ,其中,12 为步长,16 为特征维数,7 为意图类别总数。

2.2.1 输入层

特征预测模块输入层已经把采集的空中目标作战意图特征进行清理并归一化,所以本输入层主要是进行意图识别模块样本数据的构建。假设利用前  $n$  个时刻的特征数据,预测该段时间内的意图,其函数映射关系为:

$$Q_1 = f(v_1, v_2, \dots, v_{11}, w_{12}) \quad (8)$$

式中: $Q_1$  为在时间段 1~12 时刻内预测的意图类型; $v_i, i \in (1, 2, \dots, 11)$  为在第  $i$  时刻的历史特征数据; $w_{12}$  为在第 12 时刻特征预测模块预测的特征数据。

选取  $(v_1, v_2, \dots, v_{12})$  为第 1 组输入数据,标签为 1~12 时间段对应的意图类型  $q_1$ ;以  $(v_2, v_3, \dots, v_{13})$  为第 2 组输入数据,标签为 2~13 时间段对应的意图类型  $q_2$ 。以此类推,组成如下所示的训练样本输入数据和训练样本标签。测试数据的构建方法与训练样本数据相类似,区别在于将每个样本最后一个时刻的特征  $v_i$  换成特征预测模块预测的特征  $w_i$ ,即输入数据为  $(v_i, v_{i+1}, \dots, v_{i+10}, w_{i+11})$ ,标签为  $i \sim i+11$  时间段内对应的意图类型  $q_i$ 。

$$\begin{bmatrix} \mathbf{v}_1 & \mathbf{v}_2 & \cdots & \mathbf{v}_m \\ \mathbf{v}_2 & \mathbf{v}_3 & \cdots & \mathbf{v}_{m+1} \\ \vdots & \vdots & & \vdots \\ \mathbf{v}_{11} & \mathbf{v}_{12} & \cdots & \mathbf{v}_{m+10} \\ \mathbf{v}_{12} & \mathbf{v}_{13} & \cdots & \mathbf{v}_{m+11} \end{bmatrix} \quad (9)$$

$$[\mathbf{q}_1 \quad \mathbf{q}_2 \quad \cdots \quad \mathbf{q}_m] \quad (10)$$

经过上面样本数据构建后,再把意图标签通过独热(one-hot)编码处理即可输入到下面的隐含层中。

### 2.2.2 隐含层

隐含层中含有 BiGRU 网络层和 Attention 机制层。Attention 机制与人脑观察物体的原理相类似,会根据目的有重点的关注物体的局部内容。在本文中,Attention 机制通过计算不同时刻 BiGRU 网络中输出的特征向量的权重,突出对预测结果占比更大的特征,从而使整个模型表现出更优异的结果。在空中目标作战意图识别中,神经网络在训练过程中通过 Attention 机制来重点关注一些关键的特征,其实现方式是通过分配权重系数。首先是学习各个特征的重要程度,而后根据其重要程度分配相对应的权重系数,例如敌机是突防意图时,其飞行高度和航向角等特征会被 Attention 机制分配更高的权重来加深模型记忆。Attention 机制模型的结构如图 8 所示<sup>[28]</sup>。

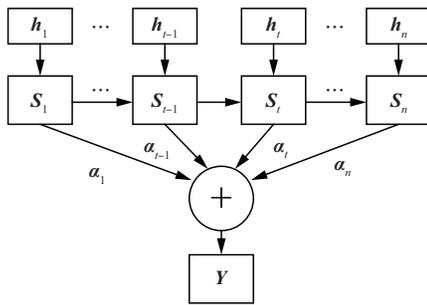


图 8 Attention 机制模型

Fig. 8 Attention mechanism model

首先,将 BiGRU 网络输出的第  $t$  个特征向量  $h_t$  输入到 Attention 机制层得到初始状态向量  $s_t$ ;其次,通过式(11)学习得到注意力权重  $e_t$ ;然后,通过式(12)即 softmax 函数对注意力权重概率化得到权重概率向量  $\alpha_t$ ;最后,通过式(13)与  $h_t$  相乘并累加和得出最终的状态向量  $Y$ 。

$$e_t = \tanh(w_w s_t + b_w) \quad (11)$$

$$\alpha_t = \frac{\exp(e_t u_w)}{\sum_{i=1}^t (\exp(e_i u_w))} \quad (12)$$

$$Y = \sum_{i=1}^n \alpha_i s_i \quad (13)$$

式中: $w_w$  为权重系数矩阵; $b_w$  为偏置系数矩阵; $u_w$

为随机初始化的注意力矩阵。

### 2.2.3 输出层

将 Attention 机制层的输出输入到多分类激活函数 Softmax 中,输出概率最高的空中目标作战意图标签,将标签按图 2 中的解析即可识别出敌方空中目标作战意图。

$$y_k = \text{softmax}(wY + b) \quad (14)$$

式中: $w$  为带训练的权重系数矩阵; $b$  为带训练与其对应的偏置矩阵; $y_k$  为输出的预测标签。

## 3 实验分析

### 3.1 实验数据集及环境

本实验以某空域无人机近距离交战为研究背景,实验数据从某作战仿真系统中提取。采用本文所述的特征处理与编码方式,每个样本参考文献[7]采集敌方空中目标连续 12 帧的状态特征。构建 10 000 个样本(包含 8 000 个训练样本,2 000 个测试样本),其中,每个样本的每 1 帧信息包括飞行速度、飞行高度、方位角和干扰状态等 16 维特征。由于样本集数据量较大,选择由空战领域专家根据空战知识经验编写意图识别规则来生成意图标签,之后通过计算机按预置规则生成意图类型标签,最后由空战领域专家对存在意图分类歧义的样本数据修正。数据集标签中包括 7 种意图类型,各作战意图数据占比情况为监视意图 11.8%、侦察意图 14.65%、佯攻意图 18.15%、攻击意图 18%、突防意图 13.9%、撤退意图 12.3%、电子干扰意图 11.2%。

实验使用 Python3.8 语言,在 Quadro RTX 5000/PCIe/SSE2 GPU 和 CUDA11.0 加速环境下进行,采用 Keras2.4.3 深度学习框架,电脑配置为 x86-64 CentOS7 PC 系统、Intel® Xeon(R) Silver 4110 CPU @2.10 GHz、64 GB 内存。

### 3.2 意图识别模块实验分析

本实验所使用的数据并不包含特征预测模块预测得到的未来特征,即每 1 个样本中的 12 帧时序特征皆为历史特征,并没有加入预测特征,其目的是为同其他文献提出的意图识别方法进行对比,验证本文所提出意图识别方法的优越性,而意图预测实验将在 3.4 节展开说明。

#### 3.2.1 网络结构选取

利用 PSO 选取 BiGRU 的最优网络结构,共选取隐藏层层数、隐藏层节点数、批量大小、学习率 4 项参数。设置其上下限为  $[4, 500, 1\ 000, 0.005]$ ,  $[1, 10, 100, 0.000\ 1]$ 。设置意图识别错误率作为适应度函数,最大迭代次数 20,种群规模 30。得到实

验结果和其它关键超参数的设置如表 1 所示。

表 1 实验参数

Tab. 1 Experimental parameters

参数	值
损失函数	交叉熵损失函数
优化器	Adam
Dropout	0.5
隐藏层层数	3
隐藏层节点数	334,10,338
批量大小	100
学习率	0.001 4
训练周期	200

3.2.2 意图识别结果分析

BiGRU-Attention 意图识别模块经训练后输入测试样本,实验表明,本文提出的意图识别网络模型准确率达到 91%。为进一步观测各识别意图之间的关系,制作了测试样本意图识别结果混淆矩阵,对角线表示识别正确的样本个数,纵轴为真实标签,横轴为预测标签,结果如图 9 所示。

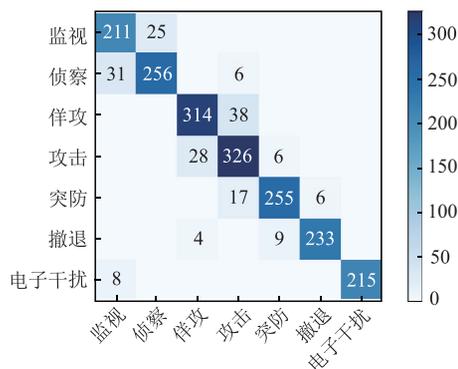


图 9 意图识别混淆矩阵

Fig. 9 Confusion matrix of intention recognition

从图 9 中能够看出,BiGRU-Attention 意图识别模型对于 7 种意图都有较高的识别精准率和召回率,特别是电子干扰意图识别精确率可达到 100%,召回率可达到 96%。对于监视意图与侦察意图,佯攻意图与攻击意图之间都存在少部分相互识别错误的情况,经分析是由于 2 种意图之间的特征相似性较高、意图欺骗性更强,BiGRU 神经网络无法确保训练的模型权重在识别两者意图之间有明显差异,致使最后的注意力机制层无法准确感知两者之间的权重差异,从而导致有少部分意图相互识别错误的情况出现,符合实际情况。

3.2.3 对比实验

本实验选取 200 次迭代过程中测试集最高准确率为意图识别模型的准确率,相对应的损失值为意图识别模型的损失值。通过本文提出的 BiGRU-

Attention 意图识别模型与文献[9]提出的基于 LSTM 的战场对敌目标战术意图识别模型,文献[7]提出的使用 Adam 算法和 ReLU 函数优化 DBP 神经网络的空中目标作战意图识别模型,文献[10]提出的栈式自编码器战术意图智能识别模型进行对比使用,对比实验参数设置如表 2 所示,实验结果见表 3。

表 2 对比实验参数设置

Tab. 2 Compare model parameter settings

模型	隐藏层 层数	隐藏层 节点数	学习率	优化器
SAE	3	256,128,128	0.020	SGD
LSTM	3	256,128,128	0.001	Adam
DBP	4	256,512,512,256	0.010	Adam

表 3 4 种模型实验结果

Tab. 3 Experimental results of four models

模型	准确率/%	损失值
BiGRU-Attention	90.5	0.257
LSTM	87.6	0.346
SAE	81.3	0.473
DBP	79.3	0.492

从表 3 可看出,本文提出的 BiGRU-Attention 意图识别模型较其他 3 种模型在准确度和损失值两方面都更加优异,较 LSTM 模型准确率提高 2.5%,同 SAE 和 DBP 模型相比提高近 10%,从而验证本文提出的模型对空中目标作战意图识别的有效性。此外,BiGRU-Attention 与 LSTM 作为以循环神经网络为基础的时序特征网络,较其他 2 种模型更加适用于空中目标作战意图识别,进一步说明依据时序特征变化来推理空中目标作战意图更具有科学性。

3.2.4 消融实验

虽然 BiGRU-Attention 意图识别模型在对比实验中已经验证其对于空中目标作战意图识别的有效性,但对比方法毕竟不属于同种类型的混合实验模型的对比。因此,本文在同一数据集上进行消融实验,其实验结果如表 4、图 10、图 11 所示。

表 4 消融实验结果

Tab. 4 Results of ablation experiment

各模型组成结构			准确率/%	损失值
Bi-directional	GRU	Attention		
✓	✓	✓	90.5	0.257
	✓	✓	88.6	0.305
✓	✓		88.9	0.289
	✓		87.4	0.337

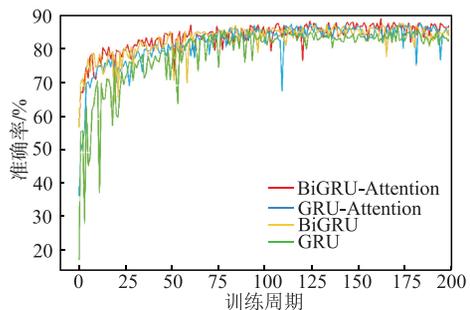


图 10 消融实验准确率变化情况

Fig. 10 Changes in accuracy of ablation experiment

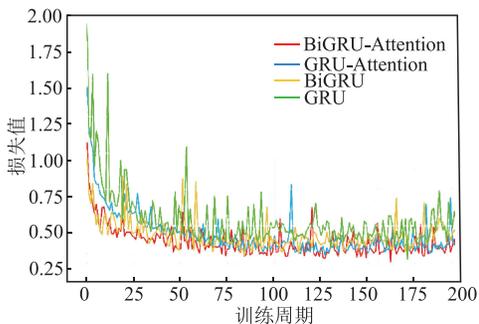


图 11 消融实验损失值变化情况

Fig. 11 Changes in loss of ablation experiment

从表 4 可得出,本文所提的 BiGRU-Attention 意图识别模型对比 GRU、BiGRU、GRU-Attention 意图识别模型准确率分别提升 2.7%、1.9%、1.6%,损失值也更低,BiGRU 与 GRU-Attention 模型准确率和损失值相近且优于 GRU 模型。从图 10、图 11 中可以看到,4 种模型准确率随训练周期增长而不断提高,损失值不断下降;BiGRU-Attention 和 BiGRU 模型大约在 50 轮次左右准确率和损失值达到收敛状态,其余 2 种模型大约在 70 轮次左右达到收敛状态,故分析应是引入双向传播能够有效提高模型收敛速度,使得更快地学习;BiGRU-Attention 模型曲线明显优于其余 3 种;BiGRU 和 GRU-Attention 模型在收敛之后的准确率和损失值曲线相近且优于 GRU 模型,可见通过引入注意力机制和双向传播机制对基础 GRU 模型有显著提升。

### 3.3 特征预测模块实验分析

该模块的任务是预测敌方空中目标未来特征,而后将其输入到意图识别模块,预测出敌方空中目标意图。采用 16 维特征均方误差的平均值(以下简称误差)作为评价指标。

#### 3.3.1 网络结构选取

网络结构主要是设置滑动步长、隐藏层层数和隐藏层节点数量。由于隐藏层数量的增加会造成时间成本的快速增加,考虑到空战对时效性的高要求,设置为单层或双层隐藏层结构,不考虑设置更多隐藏层。滑动步长选取实验与隐藏层节点数量选取实验结果如图 12 和图 13 所示。

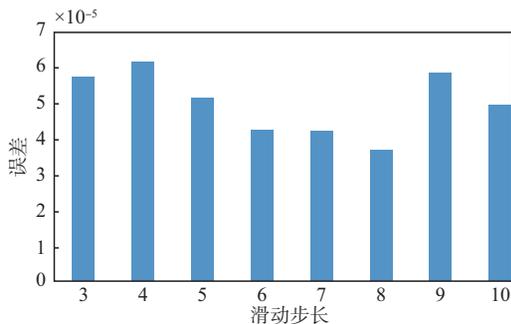


图 12 预测精度与滑动步长

Fig. 12 Prediction accuracy and sliding step size

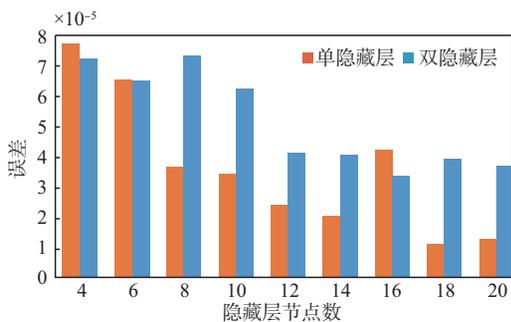


图 13 预测精度与节点数

Fig. 13 Prediction accuracy and node number

由图 12 和图 13 可知,滑动步长为 8 时预测均方误差平均值最小,单隐藏层节点数为 18 时预测均方误差平均值最小。因此选择滑动步长为 8,单隐藏层,网络节点数为 18 的网络结构。其他超参数设置:优化器 Adam、初始学习率 0.001、衰减率 0.9、训练周期 200 轮、批量大小 512。

#### 3.3.2 对比实验

为验证提出的特征预测模块切实有效,在实时性和均方误差平均值两方面与 RNN、LSTM、GRU 和 BiLSTM 网络进行对比,并选取敌方双方距离这一特征的一段预测轨迹与实际轨迹进行对比。结果如表 5 和图 14 所示。

表 5 5 种模型实验结果

方法	误差	预测时间/ms
RNN	$8.14 \times 10^{-5}$	0.089
LSTM	$2.75 \times 10^{-5}$	0.133
GRU	$2.46 \times 10^{-5}$	0.110
BiLSTM	$1.29 \times 10^{-5}$	0.311
BiGRU	$1.16 \times 10^{-5}$	0.202

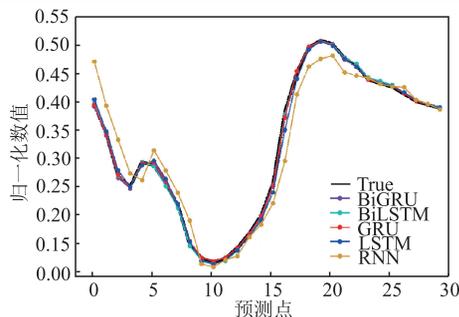


图 14 特征预测轨迹

Fig. 14 Characteristic prediction trajectory

从表 5 可以看出,BiLSTM 单步预测时间最长为 0.311 ms,RNN 单步预测时间最短,但其预测误差较大为  $8.14 \times 10^{-5}$ 。BiGRU 预测误差最小且单步预测时间较 BiLSTM 下降约  $\frac{1}{3}$ ,可得 BiGRU 在与 BiLSTM 性能相近甚至更优的情况下,其内部结构复杂度更低,使得其预测时间更短。BiGRU 相比 GRU 预测误差下降一半,可得双向传播机制较单向传播能够有效利用未来时刻信息,虽然 BiGRU 比 GRU 单步预测时间更长,但相对于 0.5 s 的采样间隔,0.202 ms 单步预测时长也能及时地提供预测信息。从图 14 可以看出,RNN 预测的特征轨迹与实际特征轨迹拟合程度较低,其余 4 种方法预测的特征轨迹拟合程度较高,与表 5 中的误差结果相吻合。

3.4 意图预测实验分析

本实验使用特征预测模块预测得到的未来特征状态与历史特征状态组合成 12 帧时序特征,即前 11 帧为历史特征,第 12 帧为预测得到的未来特征,样本数据构建方式见 3.1 节。

为验证本文提出的意图预测方法确能有效提前识别敌方意图,现与 3.2 节中不具有预测效果的意图识别方法进行对比,并引入精确率、召回率、F1-分数 3 种模型评估指标,进一步验证模型优越性,结果见表 6 和图 14 所示。

由如图 15、图 16 以及表 6 可知,本文提出的意图预测方法对于撤退意图和电子干扰意图的预测准确率较高,对于监视和攻击意图识别准确率相对较低。经分析,前两者意图的空战特征较为明显,后两者意图与侦查和佯攻意图空战特征较为相似,所以出现相互预测错误的情况,导致意图预测准确率相对较低。总体上,本文提出的意图预测方法准确率可达 89.7%,与 LSTM<sup>[9]</sup>、深度反向传播神经网络模型(deep back propagation,DBP)<sup>[7]</sup>和堆栈自编码器(stacked autoencoder,SAE)<sup>[10]</sup>意图识别方法相比,不仅在准确率方面有明显提升,而且能够提前 1 个采样点(0.5 s)时刻预测。与本文提出的不具有预测效果的 BiGRU-Attention 意图识别方法相比准确率仅下降 0.8%。

此外,尝试提前 2 个采样点预测敌方意图,结果并不理想,准确率仅能达到 70%。分析原因,应是特征预测模块两步预测相比单步预测,误差累积过大,拟合程度不高,导致意图预测准确率不高。但是,随着多步预测方法的不断提出和改进,相信本文提出的空中目标作战意图预测方法能有更好的应用前景。

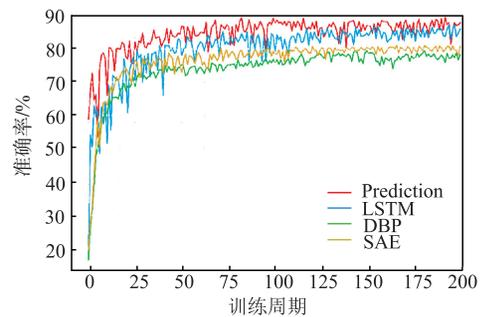


图 15 4 种模型准确率变化情况

Fig. 15 Changes in accuracy of four models

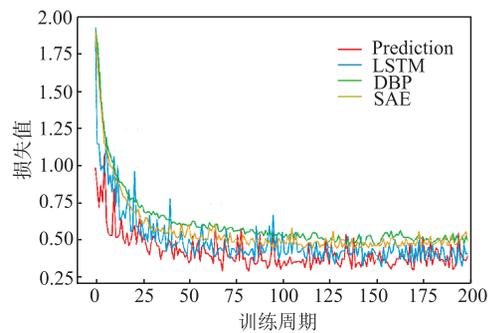


图 16 4 种模型损失值变化情况

Fig. 16 Changes in loss of four models

表 6 意图识别性能度量

Tab. 6 Intention recognition performance measurement

意图	精确率/%				召回率/%				F1-分数			
	本文方法	LSTM	DBP	SAE	本文方法	LSTM	DBP	SAE	本文方法	LSTM	DBP	SAE
监视	83.0	79.2	70.5	68.7	90.0	85.6	77.1	75.4	0.859	0.823	0.737	0.719
侦察	89.9	86.8	81.0	76.3	85.3	78.8	75.4	72.4	0.876	0.826	0.781	0.743
佯攻	90.6	89.1	82.5	78.1	85.4	82.9	73.8	75.5	0.879	0.859	0.779	0.768
攻击	82.3	79.6	71.2	70.2	90.6	89.7	81.4	73.3	0.862	0.843	0.759	0.717
突防	90.3	90.0	83.4	80.8	89.9	89.6	84.9	83.1	0.901	0.897	0.841	0.819
撤退	97.5	98.3	93.4	95.3	94.7	93.9	91.5	91.1	0.961	0.960	0.924	0.931
电子干扰	99.5	96.4	96.6	94.4	95.5	96.0	89.7	90.6	0.975	0.962	0.931	0.925

## 4 结语

针对空中目标作战意图识别问题,采用分层策略从敌方作战任务、双方之间威胁程度和战术动作3个角度选用16维空战特征,构建空中目标作战意图数据集,并将领域专家知识经验封装成标签。提出基于GRU的空中目标作战意图识别模型,并引入双向传播机制和注意力机制,在准确度方面较LSTM、SAE、DBP意图识别模型有明显提升。提出基于BiGRU的空战特征预测方法,实验结果表明能有效进行单步特征预测。将BiGRU-Attention意图识别模块与BiGRU特征预测模块相结合,能够在89.7%准确度情况下,提前一个采样点预测出敌方空中目标作战意图。

### 参考文献

- [1] 刘钻东,陈谋,吴庆宪,等.非完备信息下无人机空战目标意图预测[J].中国科学:信息科学,2020,50(5): 704-717.  
LIU Z D, CHEN M, WU Q X, et al. Prediction of Unmanned Aerial Vehicle Target Intention under Incomplete Information[J]. Scientia Sinica (Informationis), 2020, 50(5): 704-717. (in Chinese)
- [2] 乔殿峰,梁彦,马超雄,等.多域作战下的群目标意图识别与预测[J].系统工程与电子技术,2022,44(11): 3403-3412.  
QIAO D F, LIANG Y, MA C X, et al. Recognition and Prediction of Group Target Intention in Multi-Domain Operations[J]. Systems Engineering and Electronics, 2022, 44(11): 3403-3412. (in Chinese)
- [3] ZHANG Z, WANG H F, GENG J, et al. An Information Fusion Method Based on Deep Learning and Fuzzy Discount-Weighting for Target Intention Recognition[J]. Engineering Applications of Artificial Intelligence, 2022, 109: 104610.
- [4] 赵海洋.特定领域事件抽取与意图识别技术研究[D].西安:西安电子科技大学,2021.  
ZHAO H Y. Research on Domain-Specific Event Extraction and Intention Recognition Technology[D]. Xi'an: Xidian University, 2021. (in Chinese)
- [5] 尹翔,张萌,陈梦乔.基于判别分析的空中目标作战意图识别[J].弹箭与制导学报,2018,38(3): 46-50.  
YIN X, ZHANG M, CHEN M Q. Combat Intention Recognition of the Target in the Air Based on Discriminant Analysis[J]. Journal of Projectiles, Rockets, Missiles and Guidance, 2018, 38(3): 46-50. (in Chinese)
- [6] SONG Y, ZHANG X H, WANG Z K. Target Intention Inference Model Based on Variable Structure Bayesian Network[C]//2009 International Conference on Computational Intelligence and Software Engineering. Wuhan: IEEE, 2009: 1-4.
- [7] 周旺旺,姚佩阳,张杰勇,等.基于深度神经网络的空中目标作战意图识别[J].航空学报,2018,39(11): 322476.  
ZHOU W W, YAO P Y, ZHANG J Y, et al. Combat Intention Recognition for Aerial Targets Based on Deep Neural Network[J]. Acta Aeronautica et Astronautica Sinica, 2018, 39(11): 322476. (in Chinese)
- [8] 翟翔宇,杨风暴,吉琳娜,等.标准化全连接残差网络空战目标威胁评估[J].火力与指挥控制,2020,45(6): 39-44.  
ZHAI X Y, YANG F B, JI L N, et al. Air Combat Targets Threat Assessment Based on Standardized Fully Connected Network and Residual Network[J]. Fire Control & Command Control, 2020, 45(6): 39-44. (in Chinese)
- [9] 欧微,柳少军,贺筱媛,等.战场对敌目标战术意图智能识别模型研究[J].计算机仿真,2017,34(9): 10-14,19.  
OU W, LIU S J, HE X Y, et al. Study on the Intelligent Recognition Model of Enemy Target's Tactical Intention on Battlefield[J]. Computer Simulation, 2017, 34(9): 10-14, 19. (in Chinese)
- [10] 欧微,柳少军,贺筱媛,等.基于时序特征编码的目标战术意图识别算法[J].指挥控制与仿真,2016,38(6): 36-41.  
OU W, LIU S J, HE X Y, et al. Tactical Intention Recognition Algorithm Based on Encoded Temporal Features[J]. Command Control & Simulation, 2016, 38(6): 36-41. (in Chinese)
- [11] 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)
- [12] 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)
- [13] 张鹏程,张勇,李建国,等.基于RL-LSTM的空中目标意图识别方法[J].火力与指挥控制,2024,49(2): 75-81.  
ZHANG P C, ZHANG Y, LI J G, et al. Research on Air Target Intention Recognition Method Based on

- RL-LSTM[J]. Fire Control & Command Control, 2024,49(2): 75-81. (in Chinese)
- [14] 陆光宇,丁迎迎. 水下平台对敌意图识别技术研究[J]. 指挥控制与仿真,2012,34(6): 100-102.  
LU G Y, DING Y Y. Study on Intention Recognition to Foe of Underwater Platform[J]. Command Control & Simulation, 2012,34(6): 100-102. (in Chinese)
- [15] 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 Network Based Tactical Intention Recognition for Sea Targets [J]. Systems Engineering and Electronics, 2016, 38(8): 1847-1853. (in Chinese)
- [16] SCHMIDHUBER J. Deep Learning in Neural Networks: An Overview[J]. Neural Networks, 2015, 61: 85-117.
- [17] 滕飞,刘曙,宋亚飞. BiLSTM-Attention: 一种空中目标战术意图识别模型[J]. 航空兵器, 2021, 28(5): 24-32.  
TENG F, LIU S, SONG Y F. BiLSTM-Attention: An Air Target Tactical Intention Recognition Model[J]. Aero Weaponry, 2021, 28(5): 24-32. (in Chinese)
- [18] 郭辉,徐浩军,刘凌. 基于回归型支持向量机的空战目标威胁评估[J]. 北京航空航天大学学报, 2010, 36(1): 123-126.  
GUO H, XU H J, LIU L. Target Threat Assessment of Air Combat Based on Support Vector Machines for Regression[J]. Journal of Beijing University of Aeronautics and Astronautics, 2010, 36(1): 123-126. (in Chinese)
- [19] KOJADINOVIC I, MARICHAL J L. Entropy of Bi-Capacities[J]. European Journal of Operational Research, 2007, 178(1): 168-184.
- [20] 奚之飞,徐安,寇英信,等. 基于 PCA-MPSO-ELM 的空战目标威胁评估[J]. 航空学报, 2020, 41(9): 211-226.  
XI Z F, XU A, KOU Y X, et al. Target Threat Assessment in Air Combat Based on PCA-MPSO-ELM Algorithm[J]. Acta Aeronautica et Astronautica Sinica, 2020, 41(9): 211-226. (in Chinese)
- [21] 朱可钦,董彦非. 空战机动动作库设计方式研究[J]. 航空计算技术, 2001, 31(4): 50-52.  
ZHU K Q, DONG Y F. Study on the Design of Air Combat Maneuver Library[J]. Aeronautical Computer Technique, 2001, 31(4): 50-52. (in Chinese)
- [22] 周思羽,吴文海,李翔,等. 空战机动决策集模型分析[J]. 飞机设计, 2012, 32(3): 42-45.  
ZHOU S Y, WU W H, LI X, et al. Analysis of Air Combat Maneuver Decision Set Model[J]. Aircraft Design, 2012, 32(3): 42-45. (in Chinese)
- [23] 谢磊,丁达理,魏政磊,等. AdaBoost-PSO-LSTM 网络实时预测机动轨迹[J]. 系统工程与电子技术, 2021, 43(6): 1651-1658.  
XIE L, DING D L, WEI Z L, et al. Real Time Prediction of Maneuver Trajectory for AdaBoost-PSO-LSTM Network [J]. Systems Engineering and Electronics, 2021, 43(6): 1651-1658. (in Chinese)
- [24] 李俊生,梁伟,刘雪梅,等. 基于离差最大化的导弹中段目标威胁度评估[J]. 系统工程理论与实践, 2007, 27(5): 164-167.  
LI J S, LIANG W, LIU X M, et al. The Multi-Attribute Evaluation of Menace of Targets in Midcourse of Ballistic Missile Based on Maximal Windage Method [J]. Systems Engineering-Theory & Practice, 2007, 27(5): 164-167. (in Chinese)
- [25] 王新,杨任农,左家亮,等. 基于 HPSO-TPFENN 的目标机轨迹预测[J]. 西北工业大学学报, 2019, 37(3): 612-620.  
WANG X, YANG R N, ZUO J L, et al. Trajectory Prediction of Target Aircraft Based on HPSO-TPFENN Neural Network [J]. Journal of Northwestern Polytechnical University, 2019, 37(3): 612-620. (in Chinese)
- [26] WEI X, ZHANG L L, YANG H Q, et al. Machine Learning for Pore-Water Pressure Time-Series Prediction: Application of Recurrent Neural Networks [J]. Geoscience Frontiers, 2021, 12(1): 453-467.
- [27] 孙艺聪,田润澜,王晓峰,等. 基于改进 CLDNN 的辐射源信号识别[J]. 系统工程与电子技术, 2021, 43(1): 42-47.  
SUN Y C, TIAN R L, WANG X F, et al. Emitter Signal Recognition Based on Improved CLDNN [J]. Systems Engineering and Electronics, 2021, 43(1): 42-47. (in Chinese)
- [28] 王伟,孙玉霞,齐庆杰,等. 基于 BiGRU-attention 神经网络的文本情感分类模型[J]. 计算机应用研究, 2019, 36(12): 3558-3564.  
WANG W, SUN Y X, QI Q J, et al. Text Sentiment Classification Model Based on BiGRU-Attention Neural Network [J]. Application Research of Computers, 2019, 36(12): 3558-3564. (in Chinese)

(编辑:杜娟)