

一种基于全卷积神经网络的空中目标战术意图识别模型

李乐民, 宋亚飞, 王 鹏, 王 科

(空军工程大学防空反导学院, 西安, 710051)

摘要 针对现有空中目标识别方法敏捷性和可靠度不够高的问题, 研究设计了一种深度学习模型 MLSTM-FCN, 结合了全卷积神经网络、循环神经网络和压缩与激励模块的优点。全卷积网络能够提取空战数据中的复杂局部特征, 长短记忆神经网络可以捕捉空战意图数据的时序特征。通过消融实验和对比实验结果表明, MLSTM-FCN 模型在意图识别准确率、反应速度和抗干扰能力方面明显优于现有的空中目标意图识别模型, 取得了 sota 的结果, 为指挥员在进行空中作战决策时提供更有效的依据。

关键词 意图识别; 空中目标; 深度学习; 全卷积网络; 长短记忆神经网络; 压缩与激励模块

DOI 10.3969/j.issn.2097-1915.2024.05.013

中图分类号 V219; TP173; V917 **文献标志码** A **文章编号** 2097-1915(2024)05-0098-09

A Full Convolved Neural Network-Based Tactical Intent Recognition Model for Airborne Targets

LI Lemin, SONG Yafei, WANG Peng, WANG Ke

(Air Defense and Antimissile School, Air Force Engineering University, Xi'an 710051, China)

Abstract This paper designs a deep learning model MLSTM-FCN in combination with the advantages of fully convoluted neural network, recurrent neural network and compression and excitation module aimed at the problems that the existing air target recognition methods are not high enough in agility and reliability. The complex local features can be extracted from the air combat data by the fully convoluted network, and the long and short memory neural network can capture the temporal features of air combat intention data. The results of ablation experiments and comparative experiments show that the MLSTM-FCN model is superior to the existing air target intention recognition model in terms of intention recognition accuracy, reaction speed and anti-interference ability, and the results of sota are obtained, providing a more effective basis for commanders in making air combat decisions.

Key words intent recognition; aerial targets; deep learning; fully convoluted network; long short-term memory; squeeze-and-excitation block

随着信息化、智能化、无人化科技日益发展, 现代战争已经不能仅依赖于军事专家的经验, 还必须重视现代科技的重要作用^[1]。早在 20 世纪 70 年

代, 美国空军上校 John Boyd 就提出了博伊德循环理论 (observation orientation decision action, OODA)。从文献[2]可以看出, 在任何战争中, 都要观

收稿日期: 2023-09-20

基金项目: 国家自然科学基金(61806219, 61703426, 61876189); 陕西省自然科学基金(2021JM-226); 陕西省高校科协青年人才托举计划(20190108, 20220106); 陕西省创新能力支撑计划(2020KJXX-065)

作者简介: 李乐民(1999-), 男, 重庆合川人, 硕士生, 研究方向为态势感知、模式识别。E-mail: lemin_lee2023@163.com

通信作者: 宋亚飞(1988-), 男, 河南汝州人, 副教授, 博士, 研究方向为智能信息处理、模式识别。E-mail: yafei_song@163.com

引用格式: 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 Lemin, SONG Yafei, WANG Peng, et al. A Full Convolved Neural Network-Based Tactical Intent Recognition Model for Airborne Targets [J]. Journal of Air Force Engineering University, 2024, 25(5): 98-106.

察并获取敌军相关信息,分析敌军战略意图,从而及时调整,作出相应对策,采取相应行动。在防空领域中也不例外,对敌空中目标战术意图识别一直都是空中作战中的重要一环。

近年来,国内外研究前沿存在的主要问题是如何在智能化战场中获取战争态势,并将获取的信息充分分析,从而把握战场先机,提高决策敏捷性和可靠度。为了解决这一问题,学者们提出多种意图识别方法,包括基于统计理论、认知模型和人工智能的方法^[3]。其中,基于统计理论的方法包括贝叶斯网络、灰色关联法和证据理论。贝叶斯网络通过训练分类器提取目标的运动参数,实现目标意图分类,并利用贝叶斯优化算法提高准确性^[4]。灰色关联法将飞机运动参数转化为区间数,使用区间灰关联度描述参数相关性,实现飞机战术意图识别^[5]。证据理论融合不同来源的证据,通过模糊综合评价方法进行意图推理^[6]。基于认知模型的方法包括专家系统和模板匹配法。专家系统将专家经验转化为规则库,利用规则库进行推理分类^[7]。模板匹配法结合历史观测数据与先验知识,建立概率图模型,使用贝叶斯推理更新目标意图的后验概率^[8]。基于人工智能的方法主要包括神经网络法和深度学习。神经网络利用BP神经网络加速意图识别^[9]。深度学习将空中目标战术意图识别转化为时间序列特征的分类问题,使用双向长短期记忆网络、双向门控循环单元和卷积神经网络等模型对输入序列建模,并通过注意力机制对重要时间步加权^[10-12],实验结果表明,深度学习方法在空中目标战术意图识别任务中具有较好的性能。

上述空中目标意图识别模型存在以下问题:①识别精度不够高,这使得指挥员将难以依赖和信任该系统,从而可能会作出错误的决策,在空中作战中,由于错误的判断可能会导致无法挽回的战争损失;②系统反应速度不够快,如果系统反应速度不够快,指挥员可能会失去攻击敌方飞机的机会,从而失去战斗的制胜优势;③抗干扰能力不够强,在复杂电磁环境中,目标意图识别系统面临着各种不同类型的干扰,这可能会导致系统产生错误的判断或识别结果。

针对上述问题,本文把更多的精力放在系统精度、反应速度和抗干扰能力3个方面,并提出了空中目标战术意图识别模型 MLSTM-FCN (multivariate long short-term memory- fully convolutional networks),将全卷积网络 (fully convolutional networks, FCN) 与长短记忆网络 (long short-term memory, LSTM) 相结合,并在 FCN 中引入了压缩

与激励模块 (squeeze-and-excitation blocks, SE)。

①对于准确率方面:FCN 能够有效对数据进行特征提取,充分利用卷积神经网络在时间序列数据上的特征提取能力,提高网络的表示能力和分类性能;②对于速度方面:FCN 的结构是简单有效的,可以实现快速的特征提取和处理,同时 SE 的引入对其速度的影响相对较小,因此,整个网络具有较好的速度表现;③对于抗干扰方面:LSTM 模型对于时间序列数据中可能存在的缺失、异常等情况也有一定的容错能力,同时 SE 模块的引入提高了模型对于特征图中噪声的抑制能力,使得模型对于噪声等干扰具有较强的抵抗力。通过实验证明,模型 MLSTM-FCN 的准确率、损失值、召回率、精确率、F1 分数、模型反应速度和抗干扰能力优于现有的空中目标意图识别模型,证明了本模型的有效性。

综上,本文设计了一种深度学习模型 MLSTM-FCN,结合了全卷积神经网络、循环神经网络和压缩与激励模块的优点。相较于已有的方法,本模型在处理时间序列特征和提高识别性能方面具有独特的优势,通过实验证明,该模型在意图识别的准确率、反应速度和抗干扰能力方面表现出色,超过了现有的空中目标意图识别模型,取得了当前最优效果模型的结果,为空中作战决策提供了更有效的依据。

1 空中目标意图识别

1.1 空中目标意图识别问题描述

空中目标战术意图识别是在作战任务规划的基础上,通过观测敌方目标的行动序列集合,基于相应规则逻辑的分析推理或量化计算,推导出敌方意图的过程。在这个过程中,任务规划方和意图推理方之间存在一种相对的关系^[13]。

具体来说,任务规划方从作战意图的角度出发,将上级作战意图分解为若干任务单元执行的子任务序列。每个作战单元再将分配给自己的子任务分解为一系列元任务序列,协同作战单元依次完成系列战术行为动作从而实现相应的作战意图。因此,任务规划方是“从上往下”逐层分解作战意图的过程。意图观测推理方则是“从下往上”进行逆向推理的过程。由于敌方意图存在一定的隐蔽性和欺骗性,不能被直接观测到,只能通过逐层推理分析元意图和子意图来获取相关的信息。元意图推理分析的证据信息来自作战任务规划方遂行元意图时表现出的战术行为动作,由这些证据信息的状态序列推理出相应元意图,然后逐层逆向推理各级子意图,最终计算得到概率最大的根意图作为推理结论。任务规划方与意图推理方之间的关系如图1所示。

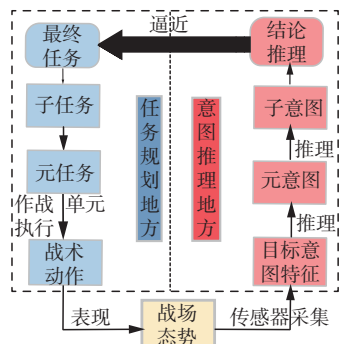


图1 目标意图推理过程

Fig. 1 Reasoning process of target intention

为了确保本文严谨性,更加准确描述识别模型,作出以下假设:①敌我双方所处的气候、大气层、空战地形等战场环境条件大致相同;②敌方空中目标战术意图在所提取的时间序列中不发生改变^[14]。

1.2 空中目标特征参数与意图空间

在定义目标战术意图空间时,需要考虑到作战形式、场景和敌方实体等因素,并根据具体情况选取合适的意图空间。根据文献[15~18]的研究成果,空中飞行目标对我水面舰艇的意图空间为侦察、监视、攻击、掩护,对我潜艇的意图空间为攻击、搜潜、驱离、巡逻。在水下作战中,目标意图空间集包括规避、巡逻和攻击,而针对单组海上舰船编队的作战意图空间集则包括撤退、掩护、攻击和侦察。文献[12]以敌无人机空袭我方军事目标为假设背景,建立的意图空间为攻击、突防、监视、侦察、佯动、撤退、电子干扰,与本文的研究背景基本吻合。因此,本文针对空中目标的战术特征建立了包含7种意图类型的空间集,即{攻击,侦察,干扰,佯攻,突防,监视,撤退}。

根据空战领域专家知识和飞行员空战经验,各种作战意图主要与目标相对距离、飞行速度、飞行高度、方位角、航向角、飞行加速度等状态参数有关。目标意图最终通过机动实现,而机动类型能反映目标的运动信息,与作战意图密切相关。本文选取12种空中目标意图特征,分为数值型与非数值型。数值型包括距离(km)、高度(m)、速度(m/s)、加速度(m/s^2)、航向角($^\circ$)、方位角($^\circ$)、雷达反射面积(m^2)。非数值型包括敌机类型、对空雷达状态、对地雷达状态、机动类型、干扰状态。

通过对非数值型数据进行编码,可以将其转化为数值型数据,便于在模型中进行处理和分析。采用以下方式:①敌机类型:将敌战斗机的种型号进行编码,使用整数进行表示;②对空雷达状态、对地雷达状态和干扰状态:将对空雷达、对地雷达和干扰装置的开启状态编码为1和0,1表示开启,0表示关闭;③机动类型:一般包括“8”字飞行、“0”字飞行、水平剪刀机动、后方追踪转弯机动、蛇形机动、俯冲、爬升等,使用不同整数进行表示。

对于数值型特征,单位不同可能导致其分布范

围存在较大差异。更大方差的特征可能产生更大的影响,从而影响获得核心特征的准确性。为了消除数据量纲的影响,提高网络收敛效率和精度,需要对其进行 min-max 标准化处理,将数据映射到[0,1]的范围内,使得不同特征的值具有可比性,从而更好地适应模型的输入要求。对于第*i*种数值型数据 $X_i = (x_{i1}, x_{i2}, \dots, x_{ik}, \dots, x_{in}) (i = 1, 2, \dots, 7), n$ 为第*i*种特征的数据个数,即:

$$x'_{ik} = \frac{x_{ik} - \min X_i}{\max X_i - \min X_i} \quad (1)$$

式中: $\max X_i$ 为某一特征 X_i 的最大值; $\min X_i$ 为某一特征 X_i 的最小值; x'_{ik} 为原始数据 x_{ik} 映射到区间[0,1]的结果。

2 意图识别模型描述

2.1 全卷积网络与 SE 模块

全卷积网络框架基于 VGG^[19] 的网络架构。VGG 在分类中取得了极大的成功,但是由于该网络最后的全连接层,导致只能接收固定大小的输入。为了克服该问题,将全连接层改为卷积层,从而可以接收任意维度的输入。由于卷积得到的特征图信息比较稀疏,需要将其上采样使之恢复到原维度。上采样的方法可以是简单的双线性插值上采样,但在文献[20]中,提出了1个反卷积上采样的方法,该方法通过实践证明更加有效。在文献[21]中提出了1个完整的反卷积网络,它包括了1个反卷积层和1个非池化层。

空中目标意图识别问题的本质是时间序列数据的分类问题,空中作战目标意图特征在本质上是多维度的时间序列信息。FCN 的多层卷积结构能够从不同的角度提取意图特征信息,只要设计适当的网络深度,就可以获得合理的感受野,从而保证网络的性能,确保意图识别特征可以被充分利用。

压缩与激励模块作为一种轻量级的通用模块,可以显示建模特征通道之间相互依赖关系,从而提升特征表示质量。这种模块可以很容易地嵌入现有最先进的卷积神经网络架构,即可为各种深度学习任务带来显著的性能提升。SE 模块主要包括 Squeeze(压缩)和 Excitation(激励)2个操作。首先,将每个二维的特征通道变成一个实数,这个实数某种程度上具有全局的感受野,将输出的维度和输入的特征通道数相匹配。然后,通过参数 w 为每个特征通道生成权重,其中参数 w 被学习用来显式建模特征通道间的相关性。最后,通过 Scale 操作将 Excitation 的输出权重用乘法逐通道加权到先前的特征上,完成在通道维度上对原始特征的重标定。软注意力通过计算注意力权重给予不同部分不同的

权重,而硬注意力通过离散的选择来选择特定的项。对于本文多变量时序数据分类问题,软注意力可以更好地帮助模型动态给予不同权重,从而更好关注和利用重要信息。因此,本文采用软注意力机制。

2.2 长短记忆神经网络

长短记忆神经网络是一种经过改进的循环神经网络(recurrent neural network, RNN),它通过引入储存单元,解决了 RNN 在长时间序列数据训练过程中的梯度消失以及梯度爆炸问题^[22]。

该网络通过更新门、遗忘门、输出门以及记忆存储单元来实现时间序列信息的输入、输出以及记忆单元的更新。 C_{t-1} 和 C_t 分别表示更新前后的细胞状态, \tilde{C}_t 代表候选神经元, h_{t-1} 表示上一时刻的隐层状态, h_t 表示更新后的隐层状态以及 t 时刻的输入向量, x_t 表示 t 时刻的输入向量。 σ 表示 sigmoid 函数,其输出位于 $0 \sim 1$ 之间。 \tanh 代表双曲正切函数,其输出位于 $-1 \sim 1$ 之间。 f_t 、 i_t 、 o_t 分别代表遗忘门、输入门、输出门。具体运算方程式如下:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

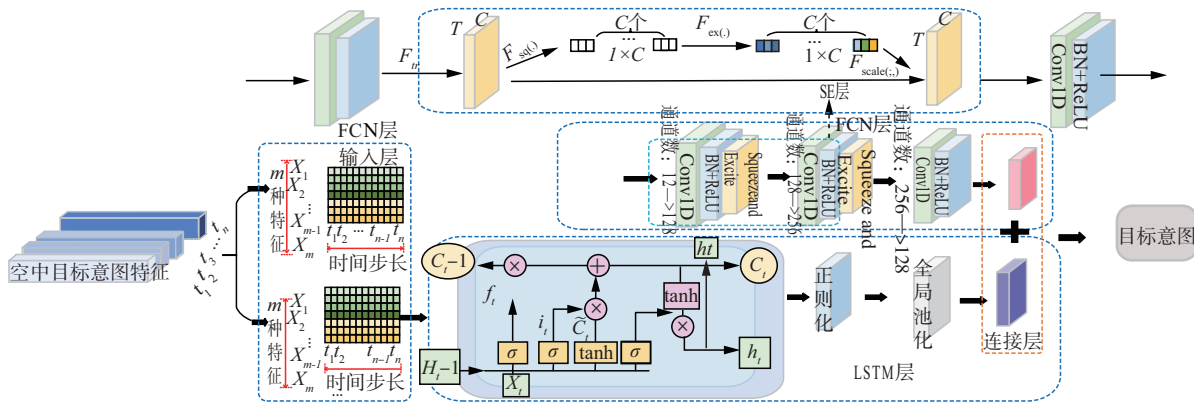


图 2 模型整体结构

Fig. 2 Overall structure of the model

全卷积块包含 3 个时间卷积块,用作特征提取器。卷积块包含 1 个卷积层,具有一定数量的过滤器(128、256、128),每个卷积层之后都是批归一化层,动量为 0.99,epsilon 值为 0.001。批归一化层之后是 ReLU 激活函数。此外,前 2 个卷积块以 SE 块结尾,对于所有的 squeeze 和 excitation 块,将缩减比例 r 设置为 16。最后的时间卷积块后面是 1 个全局平均池化层。SE 块是对 FCN 块的一种补充,它可以自适应地重新校准输入的特征映射。由于缩减比例 r 设置为 16,需要学习这些自注意力映射的参数数量减少,因此整体模型的大小仅增加了 3%~10%,可以通过以下方式计算:

$$P = \frac{2}{r} \sum_{s=1}^s R_s \cdot G_s^2 \quad (8)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (5)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (6)$$

$$h_t = o_t * \tanh(C_t) \quad (7)$$

式中: b_f 、 b_i 、 b_c 、 b_o 与 W_f 、 W_i 、 W_c 、 W_o 分别为各部分的偏移向量和权重系数矩阵。

2.3 模型整体框架

MLSTM-FCN 将它们各自的单变量模型转换为多变量变体,然后将 Squeeze-and-Excite 块扩展到 Conv1D 序列模型,并增强 LSTM-FCN 的完全卷积块,以提高分类准确性。

由于数据集现在由多变量时间序列组成,可以将时间序列数据集定义为形状为 (N, Q, M) 的张量,其中, N 是数据集中样本的数量, Q 是所有变量中的最大时间步数, M 是每个时间步处理的变量数。因此,单变量时间序列数据集是上述定义的一个特例,其中, M 为 1。LSTM-FCN 需要对输入进行修改,以接受每个时间步的 M 个输入,而非每个时间步 1 个输入。模型由全卷积块和 LSTM 块组成,如图 2 所示。

式中: P 为额外参数的总数; r 为缩减比例; s 为阶段的数量; G_s 为阶段 s 的输出特征映射的数量; R_s 为阶段 s 的重复块数。

3 实验分析

3.1 实验数据与配置

本实验的研究是针对某空域无人机交战场景进行的。使用作战仿真系统(air combat maneuvering generator, ACMG),系统中的数据作为实验数据来源,通过多次运行仿真系统,得到了多种空战意图模式,并从中随机抽取了 10 500 个空战意图样本。每个样本采集了连续 12 帧信息,每帧信息包括 12 个维度特征信息,共计 12 个时间步长。本文提出的模型

严格遵循专家的判断结果,可以在理论上应用于实际作战中,并为指挥官的指挥决策提供准确辅助信息。战术意图数据占比情况为攻击意图 8.71%、侦察意图 4.95%、干扰意图 14.3%、佯攻意图 28.4%、突防意图 28.3%、监视意图 8.29%、撤退意图 6.71%。

将样本集按照 8:2 划分为训练集和测试集,其中训练集样本规模为 8 400,测试集样本规模为 2 100。在进行实验过程中,对存在意图分类歧义的样本数据进行了修订,以确保数据集的准确性和可靠性。

本实验使用 Python 3.7,在 NVIDIA GeForce 2080Ti GPU 和 CUDA 12.1 加速环境下进行了实验,采用 Pytorch 深度学习框架,在 x64-based PC 系统、Intel © CoreTM i5-13400F CPU @2.50 GHz、32 GB 内存的电脑上进行了实验。模型超参数如表 1 所示。

表 1 模型中的超参数

Tab. 1 Hyperparameters in the model

超参数	值
优化器(Optimizer)	Adam
批大小(Batch_size)	32
训练周期(Epoch)	200
学习率(Learning rate)	1×10^{-4}
FCN 通道数(FCN out_channels)	128,256,128
FCN 卷积核大小(FCN kernel_size)	8,5,1
LSTM 层数(LSTM layers)	1
LSTM 输出维度(LSTM output dimension)	128
SE 层数(SE layers)	2
正则化参数(Dropout)	0.3

3.2 性能评估指标

为了评估本文提出的 MLSTM-FCN 空中目标作战意图识别模型的性能,本文采用准确率(A)、损失值(L)、精确率(P)、召回率(R)、F1 分数(F1),5 种指标进行分类情况的评估,计算式分别为:

$$A = \frac{\sum_{r=1}^N X_r}{\sum_{r=1}^N X_r + \sum_{r=1}^N \sum_{l=1}^N Y_{r,l}}, (r \neq l) \quad (9)$$

$$L = -\frac{1}{M} \sum_{m=1}^M \sum_{n=1}^N p(x_{m,n}) \ln q(x_{m,n}) \quad (10)$$

$$R = \frac{TP}{TP+FN} \quad (11)$$

$$P = \frac{TP}{TP+FP} \quad (12)$$

$$F1 = \frac{2 \times P \times R}{P+R} \quad (13)$$

式中: N 为训练集中意图标签的总数; M 为训练集中样本的总数;TP 为真正类;FN 为假负类;FP 为假正类; X_r 为数据集中真实标签为 r 的样本中被正

确分类的数量; $Y_{r,l}$ 为这些样本被错误分类为类别 l 的数量。

3.3 实验结果分析

3.3.1 MLSTM-FCN 结果分析

经过 MLSTM-FCN 模型在空中目标意图识别方面的训练和测试,实验结果如图 3 所示。在训练过程中,模型准确率随着轮数的增加逐渐提高,同时损失值也逐渐下降。在经过 50 轮训练后,模型已经达到收敛状态,模型损失值最低可以降到 0.008 左右,这也说明模型的训练非常充分,可以有效地学习到数据集中的特征。




图 3 MLSTM-FCN 模型的损失值

Fig. 3 Loss values for the MLSTM-FCN model

为了进一步探究各个意图之间的关系,本文采取制作混淆矩阵的方法对测试集进行了分析。混淆矩阵中的对角线表示模型正确识别的样本数,从图 4 中可以看到,撤退意图识别精度高达 100%,而佯攻的意图则相对识别精度较低,仅为 96.02%。此外,攻击意图和佯攻意图存在相互识别错误的情况,这跟 2 种意图所对应的空中目标作战意图特征相似度较高有关。网络很难从中学习到 2 种意图的明显区别,所以相互识别错误的情况也是不可避免的。这些不仅符合实际情况,也为进一步对模型进行优化提供了新的思路。

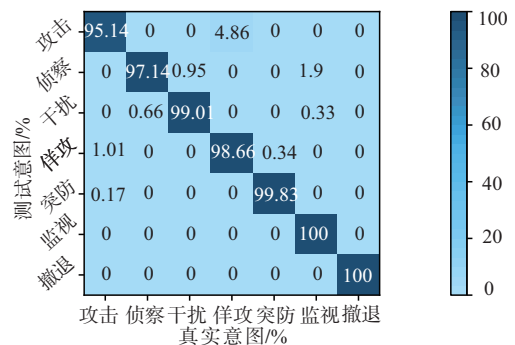


图 4 MLSTM-FCN 意图识别结果的混淆矩阵

Fig. 4 Confusion matrix for MLSTM-FCN intent recognition results

3.3.2 不同时序方法性能对比实验

在本实验中,本文采用了选取 200 次迭代过程中测试集最高准确率作为意图识别模型的准确

率,并将相对应的损失值作为意图识别模型的损失值。与此同时,在同一数据集下比较了本文提出的 MLSTM-FCN 意图识别模型、文献[10]提出的 BiLSTM-Attention 空中目标作战意图识别模型、文献[11]提出的基于 BiGRU-Attention 的战场对敌目标战术意图识别模型、文献[12]提出的基于 BiGRU-TCN 的空中目标意图识别模型、文献[23]提出的基于代价敏感的空中目标意图识别模型 BiGRU-FCN、文献[33]提出的 BiLSTM-TCN、文献[25]提出的识别作战意图的层次聚合模型、文献[26]提出的 transformer 模型的性能,实验参数为同数量级性能最好的,实验结果如表 2 所示。

表 2 6 种模型实验结果

Tab. 2 Experimental results of the six models

模型	准确率/ %	损失值	召回率/ %	F1 分数/ %	精确率/ %
MLSTM-FCN	98.86	0.008	98.90	98.45	98.14
BiLSTM-Attention ^[10]	96.45	0.067	96.64	95.61	95.39
BiGRU-Attention ^[11]	95.17	0.085	95.72	94.05	93.19
BiGRU-TCN ^[12]	95.31	0.099	94.87	93.95	93.54
BiGRU-FCN ^[23]	98.15	0.041	97.92	97.42	97.07
BiLSTM-TCN ^[24]	93.89	0.099	94.69	92.27	91.23
Hierarchical Aggregation model ^[25]	95.76	0.081	95.80	94.83	94.97
Transformer ^[26]	98.38	0.007	98.53	98.02	97.67

通过表 2 可知,本文所研究的基于时序网络的意图识别方法准确率均在 90% 以上。这表明,通过多个时序特征的连续变化来判断空中目标的意图具有更高的科学性。本文所提出的 MLSTM-FCN 模型在准确度、损失值、召回率、F1 分数和精确率 5 个方面均表现出卓越的优势,相比其他 5 种模型,其准确率均有所提高。具体而言,相较于 2 种基于 LSTM 方法的 BiLSTM-Attention 和 BiLSTM-TCN 模型,LSTM-FCN 模型的准确率分别提高了 2.41% 和 4.97%;相比 3 种基于 GRU 的方法,LSTM-FCN 模型的准确率分别提高了 3.69%、0.71% 和 3.55%。这充分证明了本文所提出模型对于空中目标战术意图识别的有效性。

为了对各个意图识别方法提取的特征进行可视化分析,本文使用了 T 分布随机邻近插入算法(T-distributed stochastic neighbor embedding, T-SNE),将不同深度学习方法提取的特征映射为二维特征。图 5 展示了这些特征的可视化图。从图中可见,MSTM-FCN 方法的类内距离较近,类间距离较

远,本文提出的方法在特征提取方面表现更佳,更容易实现分类效果。

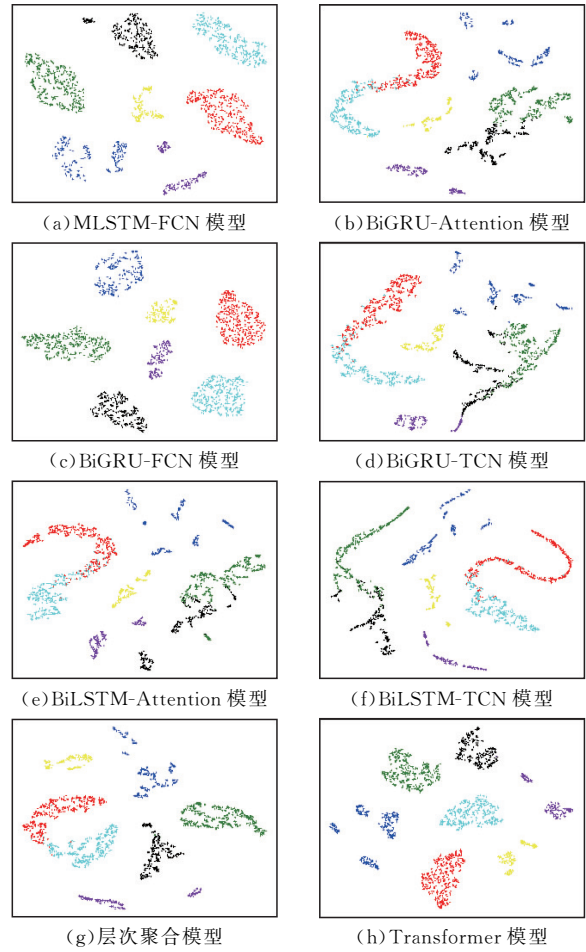


图 5 各个深度学习算法提取特征经 T-SNE 降维后投影效果

Fig. 5 Projection effect of features extracted by each deep learning algorithm after dimensionality reduction by T-SNE

对于识别的性能,模型的参数量和识别速度同样是影响能否在实战中使用的重要因素,参数量和识别速度如表 3 所示。

表 3 不同模型的性能对比

Tab. 3 Performance comparison of different models

模型	准确率/%	参数量/M	识别速度/ μ s
MLSTM-FCN	98.86	0.29	30
BiLSTM-Attention ^[12]	96.45	0.37	85
BiGRU-Attention ^[13]	95.17	0.13	34
BiGRU-TCN ^[15]	95.31	0.12	33
BiGRU-FCN ^[32]	98.15	0.31	44
BiLSTM-TCN ^[33]	93.89	1.24	38
Hierarchical Aggregation model ^[34]	95.76	0.11	37
Transformer ^[35]	98.38	0.10	160

通过对循环神经网络的层数进行堆叠,可以有

效提升对数据深层次特征的提取,提升模型识别准确率。但是由于层数增加,受到串行结构的限制,模型参数数量的增大必然会带来识别速度的降低。如何权衡两者之间的关系是需要考虑的问题。本文提出的 MLSTM-FCN 将单向 LSTM 和全卷积网络结合,相较于传统的双向 LSTM,有效降低了模型的参数量,极大提升了识别速度和准确率。

3.3.3 模型消融实验分析

通过对比实验,充分证明了 MLSTM-FCN 模型,但是由于 LSTM-FCN 模型并非同种类型混合实验模型的对比,其实验结果可能缺乏一定的实验说服力。因此,本文在同一数据集上进行了模型消融实验,实验结果如表 4 所示。

表 4 消融实验结果

Tab. 4 Results of ablation experiments

模型组成结构			准确率/%	损失值	识别速度/ μ s
LSTM	FCN	SE			
✓	✓	✓	98.86	0.008	30
✓			97.02	0.015	22
✓	✓		98.72	0.009	28
	✓		98.30	0.032	24
	✓	✓	98.44	0.028	25

结果表明,本文提出的 MLSTM-FCN 意图识别模型在准确率和损失值方面都表现出了显著的提升,相较于 LSTM、LSTM-FCN、FCN、FCN-SE 模

型,分别提升了 1.84%、0.14%、0.56%、0.42%。特别是相对于 FCN 模型,在损失值方面也表现更优秀。在识别速度方面,MLSTM-FCN 和 LSTM-FCN 在性能相差不大的前提下,后者识别速度更快,这也为下一步对模型时效性方面的改进提供了思路。

3.3.4 模型抗干扰能力分析

由于在战场环境中,一般都会因为敌方的各种干扰导致我接受到的讯号存在杂讯,为了验证本文提出的模型在战场环境下的抗干扰能力,本文对原有数据集添加了不同信噪比的高斯白噪声。根据以下公式计算信号的信噪比(SNR):

$$\text{SNR} = 10 \lg \frac{P_{\text{signal}}}{P_{\text{noise}}} = 10 \lg \frac{\sum x^2}{\sum n^2} \quad (14)$$

$$|n| = \frac{\sum x^2}{N 10^{\frac{\text{SNR}}{10}}} \quad (15)$$

$$\text{noise} = \text{random}(N) \sqrt{|n|} \quad (16)$$

式中: x 为原始信号; n 为噪声信号; N 为原始信号长度; noise 为通过信噪比计算得到的噪声信号。

本文分别在信噪比为 20 dB、10 dB、5 dB、0 dB、-5 dB、-10 dB、-20 dB 的情况下训练和测试了 MLSTM-FCN 模型,并比较了不同模型的意图识别效果,结果如表 5 所示。

表 5 各模型在不同信噪比时识别准确率对比

Tab. 5 Comparison of recognition accuracy of each model at different signal-to-noise ratios

模型	准确率/%							
	无噪声	20 dB	10 dB	5 dB	0 dB	-5 dB	-10 dB	-20 dB
MLSTM-FCN	98.86	98.15	97.02	96.88	96.45	94.89	90.77	85.94
BiGRU-Attention	95.17	92.76	91.19	88.49	84.8	84.52	75.99	63.07
BiGRU-FCN	98.15	98.01	97.16	95.45	94.46	90.20	87.50	82.39
BiGRU-TCN	95.31	92.05	89.35	87.64	86.510	81.96	69.74	65.62
BiLSTM-Attention	96.45	93.89	93.75	89.77	90.62	87.93	84.80	73.30
BiLSTM-TCN	93.89	86.93	84.80	85.09	83.38	78.98	80.68	58.52
Hierarchical Aggregation model	95.76	92.54	88.79	82.07	76.62	70.18	65.10	56.33
Transformer	98.38	97.65	92.04	88.49	82.23	77.58	74.23	69.98

可以看到,模型的准确率随着信噪比的下降而呈现出下降的趋势。但是,即使在信噪比低至 -20 dB 的情况下,MLSTM-FCN 模型准确率仍然高于其他 4 种模型,在信噪比为 0 dB 的情况下,MLSTM-FCN 模型的准确率接近 96%。相比之下,其他模型的准确率在信噪比低于 0 dB 后下降十分明显,BiGRU-Attention 甚至下降了 21.73%,说

明本文提出的模型在应对环境噪声时具有较好的鲁棒性,并且准确率变化幅度较小。

为了进一步验证模型的鲁棒性,对特征空间某些分量缺失时网络输出效果进行了分析。在该实验中,数据缺失率分别为 5%、10%、15%、20%、25%、30%。采用 2 种策略来应对数据缺失的情况。第 1 种是当数据缺失时,就对相应的数据进行补零处理,

然后再输入到模型中。第 2 种是对该特征的缺失数据沿用上一时刻的数据。实验结果如图 6 所示。




图 6 特征空间分量缺失实验结果

Fig. 6 Experimental results of missing feature space components

从图 6 可以看出,当采取第 1 种补零策略时,随着数据缺失率的提升,准确率下降幅度较明显。当缺失率达到 16% 左右时,模型准确率下降到 90% 左右。当采取第 2 种策略时,数据缺失率达到 30% 时,模型准确率仍有 93% 左右。因此,当数据缺失时,采用第 2 种方法对数据进行预处理,模型具有较高的可靠度。

4 结论

1) 提出了 MLSTM-FCN 空战目标战术意图识别模型,旨在解决当前空战目标意图识别模型精度、反应速度和抗干扰能力不足的问题。模型利用空中目标时序特征,通过 LSTM 神经网络学习连续 12 帧空战特征信息,并使用 FCN 捕捉数据间的复杂局部特征和空间特征。

2) 实验证明,相比其他模型,MLSTM-FCN 模型具有更高准确率、更快反应速度和更强抗干扰能力,取得了 sota 的结果。

需要指出的是,本文所提出的空中目标作战意图识别问题存在一个限制,即需将连续 12 帧时刻的特征作为一个样本,并假设在这个时间段内敌方意图不会发生变化,这一限制可以被视为本文研究方法的一个缺点,在下一步的研究中,可以考虑利用卷积神经网络和编码器-解码器架构来解决这个问题。

参考文献

[1] 魏岳江. 无人化是未来战争武器的发展趋势[J]. 生命与灾害, 2021(4): 24-25.
WEI Y J. Unmanned is the Development Trend of Future Warfare Weapons[J]. Life and Disaster, 2021

(4): 24-25. (in Chinese)

- [2] 李旋. 基于 OODA 环的作战网络评估与优化研究[D]. 武汉: 华中科技大学, 2021: 11-13.
LI X. Research on Evaluation and Optimization of Combat Network Based on OODA Loop [D]. Wuhan: Huazhong University of Science and Technology, 2021: 11-13. (in Chinese)
- [3] 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. 北京: 北京国信融合信息技术研究院, 2020: 186-188.
WANG H W, SHI H Q, ZHAO X Z. Overview of Target Intention Recognition Methods [C]//Proceedings of the 2020 China High-Level Forum on System Simulation and Virtual Reality Technology. Beijing: Beijing Guoxin Fusion Information Technology Research Institute, 2020: 186-188. (in Chinese)
- [4] JIN Q, GOU X T, JIN W D, et al. Intention Recognition of Aerial Targets Based on Bayesian Optimization Algorithm [C]//2017 2nd IEEE International Conference on Intelligent Transportation Engineering (IC-ITE). Singapore: IEEE, 2017: 356-359.
- [5] 戴革林, 陈伟, 刘志坚, 等. 基于区间灰关联度的飞机战术意图识别方法[J]. 数学的实践与认识, 2014, 44(20): 198-207.
DAI G L, CHEN W, LIU Z J, et al. Aircraft Tactical Intention Recognition Method Based on Interval Grey Relational Degree [J]. Mathematics in Practice and Theory, 2014, 44(20): 198-207. (in Chinese)
- [6] WANG H B, GUAN X, YI X, et al. A Fusion Recognition Method Based on Temporal Evidence Reasoning [J]. Mathematical Problems in Engineering, 2023, 2023: 5873034.
- [7] CHEN Y M, LI Y C. Simulation of Target Tactical Intention Recognition Based on Knowledge Map [J]. Computer Simulation, 2019, 36(8): 1-4, 19.
- [8] 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. Method for Recognizing Air Defense Target Intention Based on Belief Rule Base [J]. Fire Control & Command Control, 2017, 42(9): 7-12. (in Chinese)
- [9] 刘松波, 白国振. 基于 BP 神经网络的 HEV 加速意图识别[J]. 农业装备与车辆工程, 2017, 55(10): 88-91.
LIU S B, BAI G Z. HEV Acceleration Intention Recognition Based on BP Neural Network [J]. Agricultural Equipment and Vehicle Engineering, 2017, 55(10): 88-91. (in Chinese)
- [10] TAN B, LI Q N, ZHANG T L, et al. The Research of

- Air Combat Intention Identification Method Based on BiLSTM + Attention[J]. *Electronics*, 2023, 12(12): 2633.
- [11] TENG F, SONG Y F, WANG G, et al. A GRU-Based Method for Predicting Intention of Aerial Targets[J]. *Computational Intelligence and Neuroscience*, 2021, 2021: 6082242.
- [12] TENG F, SONG Y F, GUO X P. Attention-TCN-BiGRU: An Air Target Combat Intention Recognition Model[J]. *Mathematics*, 2021, 9(19): 2412.
- [13] 杨雨田, 杨杰, 李建国. 基于 EMEBN 的空中目标战术意图识别方法[J]. *火力与指挥控制*, 2022, 47(5): 163-170.
- YANG Y T, YANG J, LI J G. Method for Recognizing Air Target Tactical Intention Based on EMEBN [J]. *Fire Control & Command Control*, 2022, 47(5): 163-170. (in Chinese)
- [14] 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 UAV Air Combat Target Intention under Incomplete Information [J]. *Scientia Sinica (Information Sciences)*, 2020, 50(5): 704-717. (in Chinese)
- [15] 赵福均, 周志杰, 胡昌华, 等. 基于置信规则库和证据推理的空中目标意图识别方法[J]. *电光与控制*, 2017, 24(8): 15-19, 50.
- ZHAO F J, ZHOU Z J, HU C H, et al. Method for Recognizing Air Target Intention Based on Belief Rule Base and Evidence Reasoning[J]. *Electronics Optics & Control*, 2017, 24(8): 15-19, 50. (in Chinese)
- [16] 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. Recognition of Sea Target Tactical Intention Based on Fuzzy Neural Network[J]. *Systems Engineering and Electronics*, 2016, 38(8): 1847-1853. (in Chinese)
- [17] 张天赫, 彭绍雄, 邹强, 等. 无监督神经网络的潜艇对空战术意图识别[J]. *现代防御技术*, 2018, 46(2): 122-129.
- ZHANG T H, PENG S X, ZOU Q, et al. Recognition of Submarine-to-Air Tactical Intention Using Unsuper-
- vised Neural Network[J]. *Modern Defence Technology*, 2018, 46(2): 122-129. (in Chinese)
- [18] 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. Research on Technology for Recognizing Enemy Intention from Underwater Platforms[J]. *Command Control & Simulation*, 2012, 34(6): 100-102. (in Chinese)
- [19] SIMONYAN K, ZISSERMAN A. Very Deep Convolutional Networks for Large-Scale Image Recognition [EB/OL]. (2014-09-29)[2024-09-30]. <http://arxiv.org/abs/1409.1556v6>.
- [20] LIN G S, SHEN C H, VANDEN H A, et al. Efficient Piecewise Training of Deep Structured Models for Semantic Segmentation [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA:IEEE, 2016: 3194-3203.
- [21] NOH H, HONG S, HAN B. Learning Deconvolution Network for Semantic Segmentation[C]//2015 IEEE International Conference on Computer Vision (ICCV). Santiago, Chile:IEEE, 2015: 1520-1528.
- [22] YU Y, SI X S, HU C H, et al. A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures [J]. *Neural Computation*, 2019, 31(7): 1235-1270.
- [23] 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): 176-191.
- DING P, SONG Y F. Cost-Sensitive Method for Recognizing Air Target Intention[J]. *Acta Aeronautica and Astronautica Sinica*, 2023, 44(24): 176-191. (in Chinese)
- [24] SHIKALGAR M B, ARAGE C S. Fake News Detection Using Hybrid BiLSTM-TCN Model with Attention Mechanism [C]//2023 2nd International Conference on Applied Artificial Intelligence and Computing (ICAAIC). Salem, India:IEEE, 2023: 1130-1136.
- [25] 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.
- [26] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is All You Need[J]. *Advances in Neural Information Processing Systems*, 2017, 30: 5998-6008.

(编辑: 杜娟)