

难分类样本快速空中目标意图识别方法

赵亮¹, 孙鹏¹, 张杰勇¹, 钟赞¹, 杨富平²

(1. 空军工程大学信息与导航学院, 西安, 710077; 2. 94587部队, 江苏连云港, 222345)

摘要 针对不平衡难分类条件下空中目标群组意图快速识别的难题, 提出一种基于滑动窗口估计的时空卷积自注意力网络模型的意图识别方法。该方法根据特征数据的特点对其使用滑动窗口的预先处理, 通过时空卷积网络快速提取多维时序特征数据的流信息; 然后采用自注意力机制捕捉每个特征数据的关键特征并优化权重。仿真结果表明该方法有效提升了不平衡样本中难分类样本意图识别的训练效率和分类的准确率。

关键词 意图识别; 时空卷积网络; 自注意力机制; 难分类样本; 样本不平衡

DOI 10.3969/j.issn.2097-1915.2024.01.012

中图分类号 E824 **文献标志码** A **文章编号** 2097-1915(2024)01-0076-07

A Fast Aerial Targets Intention Recognition Method under Imbalanced Hard-Sample

ZHAO Liang¹, SUN Peng¹, ZHANG Jieyong¹, ZHONG Yun¹, YANG Fuping²

(1. Information and Navigation School, Air Force Engineering University, Xi'an 710077, China;

2. Unit 94587, Lianyungang 222345, Jiangsu, China)

Abstract Aimed at the problem that air target group intent is often difficult to be identified rapidly under condition of imbalanced and difficult classification, an intent recognition method is proposed based on moving-window estimation of the temporal convolution self-attention network model. First, the proposed model is intended to preprocess the feature data by the moving-window estimation method. Second, the flow information of multi-dimensional time series feature data is quickly extracted by the temporal convolution network (TCN). Finally, the self-attention mechanism is used to capture the key features from each feature datum and optimize the weights. The simulation results show that this method improves the training efficiency and classification accuracy for the intent recognition of hard-sample in imbalanced samples.

Key words intent recognition; temporal convolution networks (TCN); self-attention; hard-sample; imbalance sample

空中战场环境复杂、瞬息万变, 数据处理的速度尤为重要, 基于同一场地的攻击态势变化复杂, 除关键几帧的动作变化, 大量的飞行意图较为接近, 造成捕获数据高度相似。因此单纯依靠人的经验和传统方法提取相似特征, 难以满足指挥员及时准确决策

的要求, 也会影响对现有武器系统快速精准的反应。因此, 需要设计一种能够快速及时准确识别敌方空中群组意图的方法, 从而辅助指挥员决策制定。

国内外的研究中, 用于目标意图识别^[1]的方法主要有传统数学模型如专家系统^[2-3]、贝叶斯网

收稿日期: 2023-06-14

基金项目: 国家自然科学基金(61773396)

作者简介: 赵亮(1996-), 男, 陕西咸阳人, 硕士生, 研究方向为目标选择、人工智能。E-mail: adam_snowboarder@163.com

通信作者: 孙鹏(1972-), 男, 河北安平人, 教授, 博士, 研究方向为指挥决策、指挥控制技术。E-mail: 281126096@qq.com

引用格式: 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 Liang, SUN Peng, ZHANG Jieyong, 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.

络^[4-6]、灰色关联区间度^[7]、模板匹配^[8-9]、决策树法^[10]、证据网络^[11]、随机森林^[12]等,相对应的机器学习神经网络等方法^[13-17]也有许多研究者进行了探索。传统数学模型需根据场景进行精准建模,模型适配更体现当前的参数设置和经验知识的评估,对相关领域的专业知识整合要求较高,难度较大;同时,更换新的参数或移植到新的场景往往需二次建模重新评估,模型调整较大,可移植性难以保证。基于神经网络的方法,更依赖数据特征的提取捕捉,迁移至不同数据集或新场景的效果普遍较好,因此本文将延续神经网络的方法进行研究。

现有使用神经网络的方法均是在训练集各类别相对平衡以及数据相似度不高的情况下进行。不平衡问题^[18]是分类问题的一种,出现在日常生活的各个方面,是机器学习数据挖掘等领域不可缺失的一部分,只有通过正确的数据分类后,才能通过相关算法挖掘信息的潜在价值。

真实战场数据不仅存在着样本集数量的不平衡,同一战场环境的不同意图样本数据也有较高相似性,往往各类不同意图的数据在数据特征上表现为特征相似、数据的重叠区间较大。特别是从针对现有神经网络方法的仿真训练结果可以看出随着样本数量的递减,训练效果不稳定,呈现较为直观的下降趋势,即现有模型更多依赖于数据量的积累。其中,对于不平衡数据下的相似样本更是不能很好地提取特征。同时,对现有模型而言,随着数据预处理过程中数据量的扩充,伴随而来的是更大计算量和更长的训练时间。难以同时平衡消耗的内存空间或时间。

针对以上问题,本文提出 2 点解决方法:一是采用滑窗估计的方式进行样本数据的扩充,解决不平衡难分类数据的扩充问题;二是提出使用 TCN-Self Attention 模型替代现有机器学习进行空中群组意图识别的模型。

1 目标意图识别问题

本文通过空中群组特征数据集训练 TCN-Attention 网络,使得网络能利用群组的时序特征状态识别出群组意图,完整流程如图 1 所示。

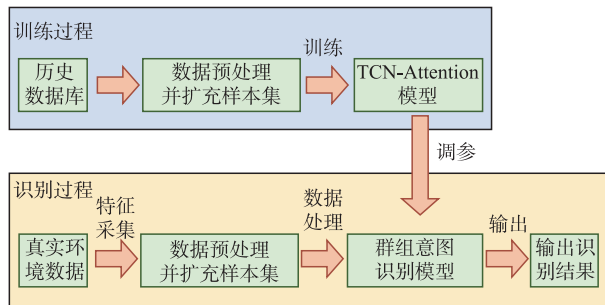


图 1 空中群组意图识别流程

1.1 意图识别定义

意图识别^[1]指通过对我方各类战场信息源、传感器等所获得的地方信息,进行综合分析,从而合理地判断、预测或解释敌方目前的作战行动意图。意图类型与时间、地点、环境、任务、规模等因素紧密关联。不同的作战意图应用的作战场景也不同。对敌方目标战术意图的识别,是从动态变化的战场态势数据中持续捕捉、抽取与敌方目标及相应时空域内战场环境信息、分析并推断敌方目标战术意图的过程。

1.2 目标群组意图判别机动特征描述

目标作战意图的不同往往体现在飞行目标的机动动作或飞行状态,即意图与机动动作或状态之间存在某种关联。从作战实际的角度出发,当敌方战机具体参与某项作战任务时,其战机的某些特征信息必须满足一定的条件。而意图的判别往往可以转化为机动动作或飞行状态的识别。机动动作或飞行状态的识别又可进一步化为对雷达数据量测和飞行特征的捕捉。

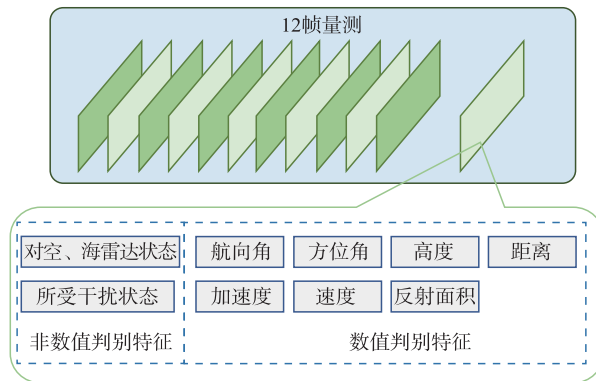


图 2 数据特征空间

图 2 为每条飞行记录的数据结构。本文选取的数据为一组动态的时序过程,将连续 12 帧雷达量测和同一时刻相对应的飞行数据封装为 1 次飞行记录,即每条飞行记录有 12 帧飞行片段;每帧飞行片段包含 9 维数据特征,即每条飞行记录包含 108 个数据。

2 样本数据预先处理

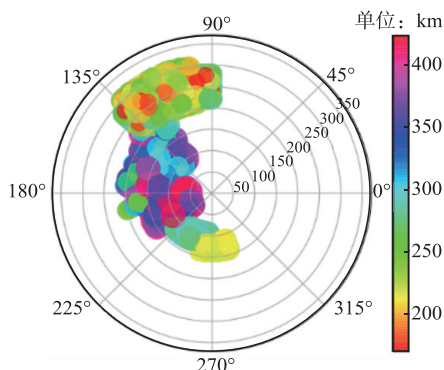
战场态势瞬息万变,真实战场环境下样本首先呈现不平衡特性;其次,受到地理位置、天气等环境外因制约,同一区域的战术行动在一定数据量的积累下会展现出一定的规律。敌方为更好地完成后续战术行动,飞行动作也会更加复杂。因此在实际测量过程中,不同标签意图的数据呈现高度相似性,对模型而言,即表现为难以对数据分类。

本文数据来自某仿真平台,表 1 为各类数据意图占比,所用的数据前期已通过领域专家完成了飞行意图的判断并通过计算机完成对数据的意图标记见图 3。


表 1 数据各意图占比

意图	训练样本	测试样本	总占比/%
攻击	140	62	1.76
电子干扰	778	338	9.70
撤退	270	109	3.30
监视	2 708	1 188	33.87
侦察	2 740	1 208	34.32
佯攻	1 364	597	17.05
合计	8 000	3 502	100.00

为了更好地分析样本特征,将对空、对海雷达的数据情况进行统计,攻击、电子干扰、佯攻意图时需要常态开启雷达,而撤退、侦察、监视意图时可能需要选择性开闭雷达。



(a) 数据高度分布情况



(b) 数据意图位置分布情况

图 3 样本点迹的极坐标分布

2.1 数据预处理步骤

数据预处理一方面是将原始数据进行格式转化,使得原始数据满足可以输入到神经网络的数据形式。另一方面,对于原始数据而言,不同标签数据的高度相似对模型的特征提取收效甚微。通过少量难分类数据的微小变化,也在一定程度上启发式地促进后续模型的特征捕捉,从而促进模型性能提升。更好地达到模型识别的效果。结构见图 4。

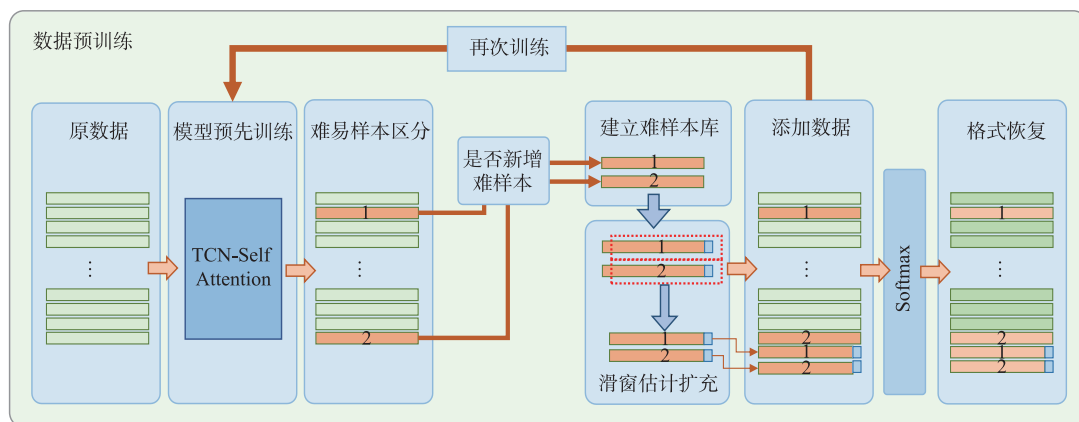


图 4 数据预处理步骤

滑动窗口估计^[19]作为一种对时间序列进行在线估计和预测的有效方法,其参数设置需要综合考虑多方面因素。通过不断验证各项参数的配比,反复实验对比,最终确定所使用的最佳参数:滑窗大小为 3,滑窗步长为 1,采样长度间隔不大于 5。

2.2 难分类样本处理方法

本文采用更换原始时空卷积网络(temporal convolutional network, TCN)结构中的激活函数实现难分类数据的非线性化,以此实现样本的特征变化,进一步方便模型的分类训练,原始 TCN 网络模型使用 ReLU 作为激活函数,其特点是速度快,但会将负值样本信息归零,造成部分归零的隐藏节点失活。为此本文引入 Leaky-ReLU、Tanh、Sigmoid 激活函数进行组合,用以代替模型原始结构中的 3 次 ReLU。

滑窗估计公式如下:

$$\begin{cases} w_j = \text{win}(d_{j-1}, d_j, d_{j+1}) \\ \Delta d = \text{mind}[w_j] \end{cases}, j \in [n-k+1, n-k+2, \dots, n] \quad (1)$$

$\text{win}()$ 为滑窗估计函数, $\text{mind}()$ 为取中位数的操作, w_j 为经过滑窗估计后得到的数据, Δd 为最终得到的采样间隔。当采样序列有 n 个采样点 x_1, x_2, \dots, x_n 那么采样点之间会产生 $n-1$ 个采样间隔 $d_j = x_i - x_{i-1}, i \in [2, 3, \dots, n]$, 根据实际应用需要可自行确定使用 k 次滑窗估计产生估计值,并且对估计值排序后取中位数,作为新与旧点最后一帧之间的估计间隔。

2.3 意图编码

空中目标群组规模平均 2~5 架次,当敌方飞行小队来袭时,优先查找该小队最具特征的一组或几

组特征群组用以代替敌方目标小队整体。

本文最终确定意图共计 6 类{攻击、撤退、电子干扰、监视、侦察、佯攻},前期经过领域专家对数据展现的飞行动作进行判别以及计算机数据标记,完成 6 类飞行意图评判。由于该 6 类意图不能直接作为神经网络的评判依据,因而本文对 6 类目标行为对应编码为{0, 1, 2, 3, 4, 5}。

3 TCN-Self Attention 空中目标意图识别模型

在真实空中群组目标意图识别环境中,模型的训练时长和内存资源消耗对现实平台的设计搭建运用影响较大,因此是模型的时间空间消耗评估中最需考虑的关键指标。为此,本文引入添加注意力机制的 TCN 时空卷积网络。

3.1 TCN-Self Attention 隐藏层结构

3.1.1 TCN 结构

为了提高意图识别模型对数据信息的利用效率,引入了 TCN(时空卷积网络)模型,文献[21]证明了在不同通用数据集条件下(含通用序列数据集条件如:MNIST、Adding problem、Copy memory、Music JSB、Music Nottingham、PTB、Wiki-103、LAMBADA、text8),TCN 网络效果要明显好于传统针对 RNN 及其衍生应用于处理序列问题的神经网络。

TCN 结构如图 5 所示。其中 input_size 为输入数据的尺寸,hidden 为每个隐藏层对应的节点数, k 为卷积核的大小,dilator 为不同层的采样间隔,level 为膨胀卷积的层数。padding 为填零操作以保证输入满足尺寸要求,dilated 为膨胀卷积运算, $F \in (\text{Relu}, \text{Leakey Relu}, \text{Tanh}, \text{Sigmoid})$ 为激活函数,Dropout 的引入用于防止模型训练过拟合。

TCN 模型使用膨胀卷积网络^[20],相对于传统卷积神经网络而言,膨胀卷积网络拥有更大的感受野,能更好地提高模型对于输入数据的特征提取。计算公式如下:

卷积层的输出尺寸:

$$\text{output} = \left\lfloor \frac{(\text{input} + 2\text{padding} - \text{kernel})}{\text{stride}} \right\rfloor + 1 \quad (2)$$

膨胀卷积核的尺寸:

$$\text{kernel}' = (\text{dilation} - 1) \times (\text{kernel} - 1) + \text{kernel} \quad (3)$$

式中:input 为卷积运算的输入尺寸;output 为卷积运算的输出尺寸;kernel 是卷积核的尺寸; $\lfloor \cdot \rfloor$ 表示向下取整;kernel' 为膨胀卷积核的等效尺寸;dilation 为膨胀卷积间隔。膨胀卷积运算输出尺寸只需将 kernel' 带入公式即可。

膨胀卷积的采样间隔满足如下公式: $\text{dilation} = 2^{\text{level}-1}$,TCN 网络通过较少的层数捕获较大的感受野,也能够方便进一步数据特征的提取。

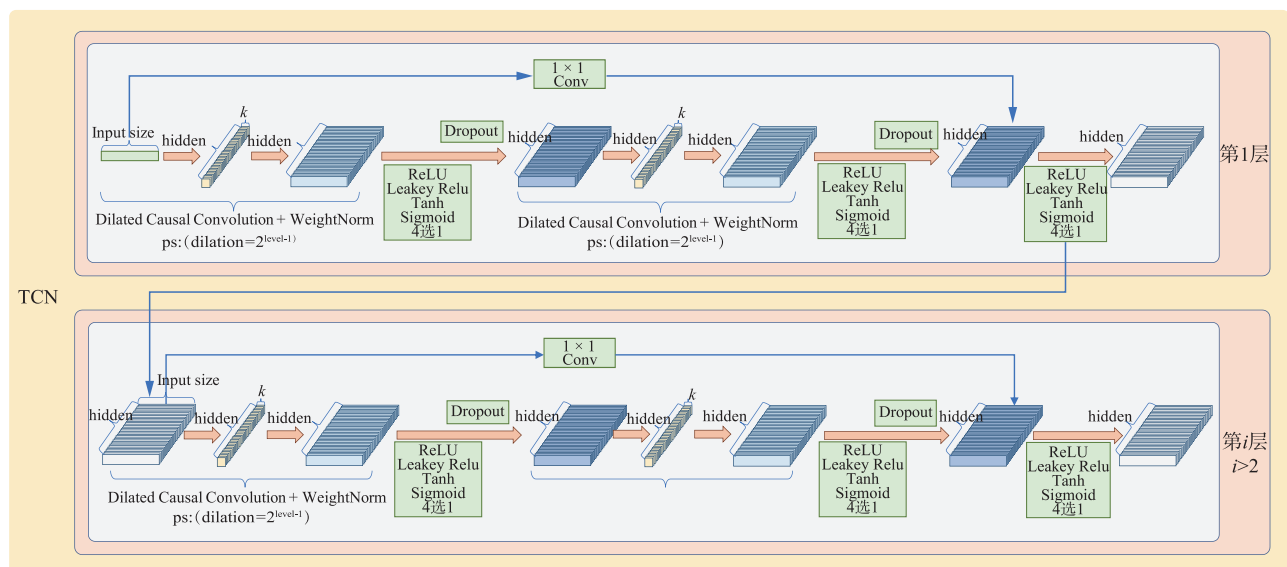


图 5 TCN 网络结构

3.1.2 Self-Attention 自注意力机制

为了使 TCN 网络能够更好地捕捉数据特征关键信息,提高模型分类识别性能,本文在 TCN 网络的隐藏层和全连接层之间引入自注意力机制 Self-Attention,使用乘性模型,通过训练优化注意力层的权重分布,最后经过加权汇总得到最终输出向量。

计算式如下:

$$Y_i = \text{soft max}(D_i Q_i (D_i K_i) T) D_i V_i \quad (4)$$

式中: D_i 为经过 TCN 膨胀卷积后的第 TCN 个数据输出, Q_i, K_i, V_i 为 D_i 输入相关的参数矩阵(Q : Query, K : Key, V : Value), Y_i 为经过 Self-Attention 层的输出结果(其中 $i \in [1, 2, \dots, \text{epoch}]$)

3.1.3 全连接层结构

通过全连接结构将注意力层的输出节点缩小至

输出节点的数量,并完成权重的配置和 Softmax 函数的输入格式整理。公式为:

$$L_j = \text{Linears}(Y_i) = W_i Y_i + b_i,$$

$$j \in [1, 2, \dots, \text{label}], i \in [1, 2, \dots, \text{epoch}] \quad (5)$$

式中: W_i, b_i 为线性层需要训练的网络参数; $\text{Linears}(Y_i)$ 为整体隐藏层的输出; label 为分类标签的个数; epoch 为每批次读取的数据个数。

3.2 输出层结构

将 Self-Attention 层的输出作为本层的输入,隐藏层的数据通过 Softmax 函数对上一层的输出进行归一化,转化为分类标签的概率向量,进而依据概率向量对特征数据进行意图识别分类,公式为:

$$\text{predict}_{\text{label}_j} = \text{Softmax}(L_j), j \in [1, 2, \dots, \text{label}] \quad (6)$$

表 2 查准率、查全率、F1-score 结果

项目	意图	标签	TCN	TCN+SA	TCN+W	TCN+W+SA	%
查准率	攻击	0	100.00	100.00	100.00	100.00	
	撤退	1	99.40	99.70	99.70	100.00	
	电子干扰	2	99.10	100.00	100.00	100.00	
	监视	3	90.60	95.40	96.00	97.00	
	侦察	4	76.30	82.50	81.60	88.20	
	佯攻	5	100.00	100.00	100.00	100.00	
查全率	攻击	0	95.20	100.00	100.00	100.00	
	撤退	1	100.00	100.00	100.00	100.00	
	电子干扰	2	100.00	100.00	100.00	100.00	
	监视	3	71.00	79.30	77.90	86.70	
	侦察	4	92.90	96.30	96.80	97.70	
	佯攻	5	99.30	99.80	99.80	100.00	
F1-score	攻击	0	97.50	100.00	100.00	100.00	
	撤退	1	99.70	99.90	99.90	100.00	
	电子干扰	2	99.50	100.00	100.00	100.00	
	监视	3	79.60	86.60	86.00	91.70	
	侦察	4	83.80	88.90	88.60	92.70	
	佯攻	5	99.70	99.90	99.90	100.00	

表 3 各模型数据整体识别准确率

模型	TCN	TCN+SA	TCN+W	TCN+W+SA	%
准确率	87.40	91.60	91.30	94.60	

4.2 TCN-Self Attention 同往期模型结果对比

为验证本文模型结果的优越性,将本文所提的 TCN-Self Attention 模型分别与文献[8]中 SAE 网络、文献[12]中 DNN 网络、文献[15]中 BiGRU+Attention 网络文献[16] DNN-AG 以及文献[17] AT-TCNBIGRU 共同进行对比实验。

4.2.1 各模型精确性对比

为了更好展现本实验所用模型的效果,我们将不同模型所用的参数进行统一。在模型的调试仿真阶段。对每个参与对比实验的模型均做到尽可能的参数调优;进行不同模型的准确率、运算时间、内存消耗结果对比。表 4 仅列举不同模型之间共同的一

4 实验分析

本实验沿用第 2 节数据。采用基于 Annocada 平台的 python 语言,神经网络学习框架为 Pytorch,运行环境为 pycharm2021, win10。显卡为 RTX1060Ti, 16GB 内存,引入模型运行时占用的内存空间、运行速度和时间进行对比。

4.1 基于滑窗估计下 TCN-Self Attention 模型的消融实验分析

本文在分析数据分类的准确性时,主要用到 4 个评价指标,分别是准确率、查准率、查全率、以及 F1-score 作为分析指标,结果如表 2 和表 3 所示。

些结构参数。

此外本文模型对原 TCN 的激活函数有一定改进。在原 Relu 的基础上引入 Leakey-Relu、tanh、sigmoid 激活函数,因此本文模型每层待选的 3 个激活函数位相互可组合产生 64 种方案,表 5 仅列举基于本实验数据集和参数条件下结果靠前的 5 种激活函数组合。通过多次运行记录各组合下的平均最优值。

表 4 对比实验的模型参数

参数	值
Epoch	128
训练周期	100
学习率	0.008
输入形状	64×108
损失函数	Crossentropy
优化器	Adam
隐藏层总节点数	216
隐藏层结构	Hidden×level=36×6

表 5 不同激活函数的最优组合结果

激活函数组合	准确率/%	损失	训练用时/s
tanh+tanh+Relu	95.06	0.12	981.13
tanh+leakey+Relu	94.69	0.121 1	1 161.06
LeakeyRelu+tanh+tanh	94.46	0.133 2	927.44
tanh+tanh+tanh	94.17	0.148 2	1 122.14
Relu+ Relu+tanh	94.12	0.174 8	1 067.06

图 6 和图 7 为 TCN-Self Attention(浅蓝曲线)与现有意图识别模型基于本文实验数据条件下准确率对照结果。TCN-Self Attention 在分类准确度方面对以往模型均有更好的表现,其中针对以上传统模型提升效率,如表 6 所示。本节的对比实验中 TCN-Self Attention 使用激活函数为第 3 组合 lea-key+tanh+tanh。因为相比于准确率排名第 1 的 tanh+tanh+Relu 组合和排名第 2 的 tanh+leakey+Relu 组合,第 3 组激活函数生成曲线更加平滑且模型训练结果更快速更稳定。




图 6 模型准确率与数据量变化关系

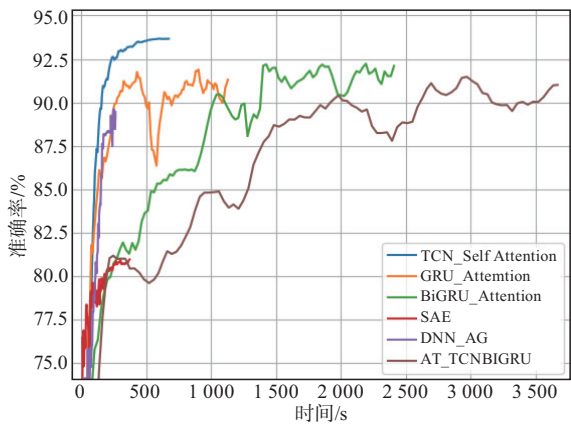


图 7 模型准确率与时间的变化关系

表 6 模型运算准确率对比

模型	准确率/%
TCN-Self Attention	94.46
BIGRU- Attention	92.98
GRU- Attention	92.83
AT-TCNBIGRU	92.39
DNN-AG	89.44
SAE	80.95

4.2.2 模型计算复杂度分析

表 7 为模型计算复杂度对比,实际运行时间以及内存消耗对比基本一致。因此,综合以上运行时间、运行内存消耗以及复杂度估计结果对比,可以认定 TCN-Self Attention 在准确率、时间效率以及空间资源消耗方面整体表现出较为完善的效果。

表 7 模型计算复杂度对比

方法	时间复杂度	空间复杂度
SAE	$O(N)$	$O(N)$
DNN-AG	$O(N)$	$O(2N)$
TCN_Self Attention	$O(8N)$	$O(10N)$
GRU_Attention	$O(48N)$	$O(12N)$
AT-TCNBIGRU	$O(56N)$	$O(22N)$
BiGRU_Attention	$O(99N)$	$O(25N)$

5 结语

本文针对空中目标群组数据量不平衡问题下的难分类数据意图识别模型进行了改进。提出了先扩充训练集中的不平衡难分类数据量,根据滑动窗口方法扩充了样本空间中的少数难分类样本数量。随后在识别过程中引入 TCN 网络及 Self Attention 机制对扩充后的样本信息进行更深层次的特征捕捉,进而提升模型意图识别的效果。最终仿真结果也表明,滑动窗口方法能够在不平衡样本的难分类数据扩充时有效保留更多原有样本细节,同时 TCN-Self Attention 模型也在不平衡样本的难分类数据空中目标群组意图识别问题上有更高的训练效率和更精准的分类效果。

然而,本文所采用的目标飞行数据集是在受控的实验条件下获得,无法充分反映实战环境的复杂性。实际作战场景中目标的飞行轨迹和活动模式会受到诸多不确定因素的影响,如天气环境、地形掩护、电子干扰等,目标也可能采用欺骗机动对抗识别。这将影响目标意图识别算法的性能。此外,现有数据集规模有限,无法充分包含各种复杂情景,也可能制约了算法的泛化性。综上,我们将在后续工作中构建更加丰富多样、包含复杂飞行情景的目标意图数据集,以提高研究的适用性。

参考文献

[1] 王端龙, 吴晓锋, 冷画屏. 对敌战场意图识别的若干问题[J]. 舰船电子工程, 2004, 24(6):4-9.
 [2] 何树权, 钱健民. 专家系统在数据融合中的应用研究[J]. 火控雷达技术, 2003, 32(1):70-77,83.
 [3] CHANG L L, ZHOU Z J, YOU Y, et al. Belief Rule Based Expert System for Classification Problems with

- New Rule Activation and Weight Calculation Procedures[J]. *Information Sciences*, 2016, 336:75-91. DOI:10.1016/j.ins.2015.12.099.
- [4] 朱波,方立恭,张小东. 基于贝叶斯网络的空中目标意图识别方法[J]. *现代防御技术*, 2012(40):109-113.
- [5] 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.
- [6] XU Y H, CHENG S Y, ZHANG H B, et al. Air Target Combat Intention Identification Based on IEDSBN [C]//International Workshop on Electronic Communication and Artificial Intelligence. Zhuhai: IWECAL,2020:36-40.
- [7] 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.
- [8] 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.
- [9] 夏曦. 基于模板匹配的目标意图识别方法研究[D]. 长沙:国防科学技术大学, 2006.
- [10] WANG L, LI S Z. Tactical Intention Recognition of Aerial Target Based on XGBoost Decision Tree [J]. *Journal of Measurement Science and Instrumentation*, 2018, 9(2):148-152.
- [11] 张瑜,邓鑫洋,李明烜,等. 基于证据网络因果分析的空中目标意图识别[J]. *航空学报*, 2022, 43(S1):143-156.
- [12] 胡智勇,刘华丽,龚淑君,等. 基于随机森林的目标意图识别[J]. *现代电子技术*, 2022, 45(19):1-8.
- [13] DENG C Y, WU K H, WANG B B, et al. Residential Appliance Detection Using Attention Based Deep Convolutional Neural Network[J]. *CSEE Journal of Power and Energy Systems*, 2022, 8(2):621-633.
- [14] 吴广宇,史红权,邱楚楚. 基于 SSA-SVM 的空中目标意图识别方法[J]. *舰船电子工程*, 2022, 42(3):29-34.
- [15] 马钰棠,孙鹏,张杰勇,等. 样本不平衡下的空中群组意图识别方法[J]. *系统工程与电子技术*, 2022, 44(12):3747-3755.
- [16] 王家鑫,王瑞琪,孟海波,等. 基于深度神经网络 Ad-aMod 优化模型的来袭目标攻击意图识别[J]. *计算机测量与控制*, 2023, 31(6):274-279.
- [17] 滕飞,邢千里,王龙飞,等. 基于时序卷积网络的空中目标作战意图识别模型[C]//2022 中国自动化大会论文集. 厦门:中国自动化学会, 2022:97-104.
- [18] 朱琳. 基于图注意力网络的类不平衡和类重叠数据二分类算法研究[D]. 济南:山东大学, 2022.
- [19] XIN Y, YANG X Y, GAO J W. Least Squares Estimation for the High-Order Uncertain Moving Average Model with Application to Carbon Dioxide Emissions [J]. *International Journal of General Systems*, 2021, 50(6):724-740. DOI: 10.1080/03081079.2021.1950150.
- [20] BAI S J, KOLTER J Z, VLADLEN K. An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling[EB/OL]. (2022-10-13) <http://arxiv.org/pdf/1803.01271.pdf>.
- [21] ZUO Y, JIANG L F, SUN H Z, et al. Short Text Classification Based on Bidirectional TCN and Attention Mechanism[J]. *Journal of Physics (Conference Series)*, 2020(1693):012067

(编辑:徐敏)