

时序数据图像化：战术意图识别及可移植框架

宋亚飞¹, 李乐民¹, 权文¹, 倪鹏², 王科¹

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

摘要: 通过将时序编码为图像, 提出了一种结合曲线滤波技术和EfficientNetV2图像识别网络的鲁棒且可移植的战术意图识别框架。曲线滤波技术可以有效地减少大量时域特征、模型参数和训练时间的冗余, 基于此, 提出了一种改进的格拉姆角场方法将时序编码为图像, 提高了卷积神经网络的特征提取能力。EfficientNetV2网络能够有效地处理意图图像, 并成为预训练模型, 使得在不同系统之间进行迁移学习成为可能。实验结果表明, 所提框架相对于机器学习及深度学习等方法提高了0.99%以上的准确率, 具有更好的性能、可扩展性、鲁棒性和可迁移性。

关键词: 时序编码; 意图识别; 图像分类; 曲线滤波; 格拉姆角场; EfficientNetV2

中图分类号: V219; TP173; V917

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2024154

Timing data visualization: tactical intent recognition and portable framework

SONG Yafei¹, LI Lemin¹, QUAN Wen¹, NI Peng², WANG Ke¹

1. Air and Missile Defense College, Air Force Engineering University, Xi'an 710051, China

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

Abstract: By transforming time series into images, a robust and transferable tactical intent recognition framework was proposed, which integrated curve filtering technology and the EfficientNetV2 image recognition network. Curve filtering technology effectively reduced redundancy in numerous time-domain features, model parameters, and training time, an enhanced Gramian angular field (GAF) method was proposed to encode time series into images, enhancing the feature extraction capabilities of convolutional neural networks. The EfficientNetV2 network was adept at processing intent images and could serve as a pre-trained model, facilitating transfer learning across different systems. Experimental results demonstrate that the proposed framework achieves over 0.99% higher accuracy compared to machine learning and deep learning methods, exhibiting superior performance, scalability, robustness, and transferability.

Keywords: time series coding, intention recognition, image classification, curve filtering, Gramian angular field, EfficientNetV2

收稿日期: 2024-05-09; 修回日期: 2024-07-29

通信作者: 宋亚飞, yafei_song@163.com

基金项目: 国家自然科学基金资助项目(No.61806219, No.61703426, No.61876189); 陕西省自然科学基金资助项目(No.2021JM-226); 陕西省高校科协青年人才托举计划基金资助项目(No.20190108, No.20220106); 陕西省创新能力支撑计划基金资助项目(No.2020KJXX-065)

Foundation Items: The National Natural Science Foundation of China (No.61806219, No.61703426, No.61876189), The National Science Foundation of Shaanxi Province (No.2021JM-226), The Young Talen Fund of University and Association for Science and Technology in Shaanxi (No.20190108, No.20220106), The Innovation Capability Support Plan of Shaanxi (No.2020KJXX-065)

0 引言

战场态势感知中,空中目标作战意图识别是至关重要的,它是战争决策支持系统的核心组成部分^[1]。2019年12月,美国知名智库战略与预算评估中心(CSBA, center for strategic and budgetary assessments)发布了《重夺制海:美国海军水面舰队向决策中心战转型》报告,其中提出了决策中心战的概念。决策中心战旨在通过大规模部署应用有人或无人分布式作战系统,并以人工智能和自主系统为关键技术支持,为指挥官提供更多可选择的“作战方案”。同时,决策中心战通过施加高复杂度的战场态势,使敌方难以做出决策来应对,从而在新的“认知域”维度上实现对敌的颠覆性优势^[2]。现代战场的复杂性和动态性急剧增加,这使得战场环境变得不确定,并且信息不完整。在面对海量复杂的战场信息时,指挥员往往难以敏锐、准确地识别目标的真实意图,从而难以控制全局战场态势^[3]。

深度学习是一种应用于战术意图识别的有效方法,其研究动机是建立和模拟人类大脑的深层神经网络,利用数据驱动的方法,从低级到高级、从具体到抽象、从一般到具体的语义提取特征,以模拟人类大脑的推理和思维过程^[4]。深度学习已成为当前人工智能领域最热门的研究方向之一。在意图推理和识别方面,深度学习已经取得了良好的效果。为了解决传统模型在知识表达和网络训练方面的困难,Teng等^[5]提出了一种名为BiGRU-Attention的空战目标战术意图识别模型,利用BiGRU神经网络对连续12帧的空战特征信息进行学习,提取更深层次的特征,并应用注意机制对特征进行权重分配,以实现准确的意图识别。Tan等^[6]提出了一种名为BiLSTM-Attention的模型,通过双向传播机制、记忆功能、遗忘机制和注意机制,更有效地处理具有时间和动态特征的数据集,探索目标意图中嵌入的因果逻辑关系。针对空中目标作战意图任务的层次性和分解的子意图序列具有长时相互依赖的特点,李颖等^[7]提出了一种层次聚合模型,用于识别目标作战意图。Teng等^[8]通过分析空中目标作战特性,设计了一种改进的时态网络TCN-BiGRU,从数据中提取潜在特征,捕获序列中存在的长期依赖关系。针对意图识别的代价敏感问题,文献^[9]设计了一种基于GRU-FCN的模型,考虑了空中目标意图的误判代价差异。周旺旺等^[10]通过引入

ReLU激活函数和Adam优化算法,提出了一种基于深度神经网络的空中目标作战意图识别方法,有效提升了模型收敛速度,并防止了陷入局部最优的问题。Teng等^[11]通过引入双向传播机制和注意力机制提出了一种基于门控循环单元的空中目标作战意图预测方法,对于实时意图识别辅助决策具有较大的参考价值和理论意义。Shikalgar等^[12]将长短期记忆神经网络和时序卷积网络相结合提出了BiLSTM-TCN模型,通过在公开可用的数据集上对模型进行实证试验,证明了其有效性。Vaswani等^[13]提出了一种全新的、基于注意力机制的网络架构,即Transformer模型,该模型完全摒弃了传统的循环和卷积结构。研究表明,仅依赖注意力机制的Transformer模型能够在时序数据处理任务中取得卓越的性能,这主要得益于其出色的全局上下文理解能力和高效的并行计算能力。Cortes等^[14]通过将输入向量通过非线性地映射到一个非常高维的特征空间,提出了支持向量网络,确保了学习机器具有高泛化能力。Rosenblatt^[15]通过训练数据找到一个线性划分的分离超平面,将特征空间划分为2个部分,分别对应不同的类别,为神经网络和支持向量机等领域的研究奠定了基础。Elman^[16]首次明确提出了简单循环网络的概念,并展示了这种网络在处理时序数据时的能力,为后续的循环神经网络(RNN, recurrent neural network)研究奠定了基础。Cho等^[17]在探讨基于RNN的编码器-解码器架构用于统计机器翻译任务时,首次提出了门控循环单元(GRU, gated recurrent unit)网络结构,解决RNN在处理长序列数据时面临的梯度消失问题,同时保持模型的简洁性和高效性。Hochreiter等^[18]围绕网络的循环连接进行循环时会呈现指数级衰减或爆炸等问题,通过引入“门”机制来控制信息的流动,使得网络能够更有效地学习和记忆长期依赖关系。

除了上述模型之外,深度学习中还存在众多在图像处理方面表现优异的技术,其中卷积神经网络(CNN, convolutional neural network)尤其突出。Tan等^[19]对卷积神经网络模型缩放进行了深入研究,通过平衡网络的深度、宽度和分辨率,使用一个简单高效的复合系数对所有维度进行统一缩放,从而扩展出一系列称为EfficientNets的模型,这些模型在精度和效率上均超越了以往的卷积神经网络。

络。Krizhevsky等^[20]训练了一个大型的深度卷积神经网络,用于对ImageNet训练集中的130万张高分辨率图像进行分类,结果明显优于之前的最先进水平。He等^[21]提出了一种残差学习框架,以简化比先前使用的网络更深的网络的训练过程,该框架通过将层重新定义为学习相对于层输入的残差函数,而非学习无参考的函数,从而降低了深层网络的训练难度。Simonyan等^[22]深入研究了卷积网络深度在大规模图像识别设置中对准确性的影响,发现将网络深度推至16~19个权重层可以显著改进先前的配置,促进计算机视觉中深度视觉表示使用的进一步研究。Transformer模型的自注意力机制允许模型同时考虑输入序列中的所有位置,从而有效地捕获长距离依赖关系,这在处理复杂时序数据时尤其重要。CNN在处理图像化后的时序数据同样具有独特的优势,其出色的局部特征提取能力和参数共享机制使得CNN在处理大规模时序数据时表现出色,尤其擅长捕捉数据的局部时空关联性。

通过分析发现,目前用于战术意图识别的深度学习框架主要都是基于时序数据模型的,并没有将强大的卷积神经网络引入其中。基于RNN的识别方法存在以下问题:①由于反向传播算法的限制,梯度可能会在时间步长上指数级地衰减或增长,导致梯度消失或梯度爆炸问题;②由于训练过程中下一步的计算依赖于前一步的结果,只能按顺序进行,导致训练时间较长,计算效率较低,极大地限制了它们在大规模数据和高性能计算环境下的应用。而基于时序卷积网络(TCN, temporal convolutional network)的识别方法通常要求输入序列具有固定的长度,这导致模型的可移植性较差。此外,TCN中的卷积层通常需要大量的参数,特别是在处理长序列时,这可能导致模型的训练和推理过程变得更加耗时和资源密集。Kuang等^[23]进行了深度CNN和长短期记忆(LSTM, long short-term memory)网络在公共数据集上的识别性能比较研究。研究结果显示,使用dropout的深度CNN在识别性能方面表现更好,并且相比于LSTM网络,深度CNN的训练时间更短。CNN是深度学习最佳模型之一,也在稳定性评估^[24-26]中得到广泛认可,如何将CNN运用在战术意图识别中,是一个十分值得研究的问题。

在实践中,现有方法可能会遇到以下3个关键

问题。首先,CNN并不直接适用于处理战场态势的时序数据,其强大的特征提取能力来自对局部特征的捕捉,在处理图像时表现出色,因为图像的局部特征具有关键的区分信息。换句话说,原始的时序数据不太适合作为CNN的输入。其次,大多数深度学习模型使用了过多的冗余信息,导致训练模型过拟合,鲁棒性不足,海量的仿真数据也给模型带来了更高的存储和训练要求。最后,输入的原始数据包包含不同仿真的动态信息和维数,差异较大,这增加了不同模型之间迁移学习的难度^[27]。

为了解决上述问题,本文提出了一种鲁棒且可移植的战术意图识别框架。基于专家的战场经验,采用了一种简单通用的曲线滤波方法。为了更有效地处理数据,从仿真数据中挑选出具有代表性的数据部分。特别地,本文关注了在仿真过程中表现出显著变化趋势、具有清晰周期性以及与其他关键数据集强关联的数据段。具体来说,选择了仿真过程中关键事件或转折点附近的数据,以及能代表整个仿真周期内主要动态变化的数据段。这些数据覆盖了仿真时间轴上的重要节点和时段,它们不仅捕捉到了数据的整体变化趋势,还体现了数据中的周期性波动以及与其他数据的关联性,能够最大程度地保留原始数据集中的关键信息和特征。通过这种方法,可以更加高效地分析和理解整个数据集,同时减少计算资源和时间的消耗。此外,这些数据对于实际战场环境也具有重要意义。它们可以帮助更准确地预测和分析战场态势的发展,为决策者提供有价值的信息支持。基于滤波结果,选取了6个特征来压缩输入特征的维数。针对意图识别中的多特征问题,提出了一种改进的格拉姆角场(IGAF, improved Gramian angular field)图像化方法。该方法利用IGAF将特征编码为RGB通道,进而将其可视化为图像。这样,大量的原始仿真数据就被巧妙地转化为RGB三通道图像,从而将战术意图识别问题转化为图像识别问题。为了进一步提升识别性能,还提出了基于EfficientNetV2的意图识别模型。得益于曲线滤波方法、IGAF以及EfficientNetV2意图识别模型在特征提取方面的卓越能力,本文提出的战术意图识别方法在性能上超越了许多其他深度学习方法。

目前的迁移学习通常基于相同的系统,而跨系统的迁移学习是一个困难的挑战。解决这个问题具

有重要意义^[14]。通过识别不同仿真系统的类似规律,使得迁移学习成为可能。同时,选择适合的迁移学习方法也非常重要。本文采用了基于模型的预训练迁移学习方法来实现这一具有挑战性的目标。核心思想是在大数据集上训练一个强模型,该模型具有丰富的不稳定信息。当用户需要在自己的小数据集上进行训练时,可以通过微调预训练的模型来快速收敛。本文提出的基于 EfficientNetV2 的意图识别模型可以作为这样一个强模型,其在特征提取方面展现出卓越的能力,以及独特的网络结构和优化策略使得战术意图识别的性能显著超越了许多其他深度学习方法。更重要的是, EfficientNetV2 不仅在当前系统的识别任务中表现出色,还因其强大的泛化能力,成为实现跨系统迁移学习的理想选择。与从头开始训练相比,微调模型具有更快的收敛速度、更低的训练成本和更强的竞争力。

本文的创新点如下。

1) 针对战场态势感知数据高维、冗余的问题,提出了一种鲁棒性、可移植的深度神经网络框架,将时序数据图像化,进行战术意图识别。

2) 使用了一种有效的时序数据滤波方法,从而有效地减少了输入特征的冗余,提高了模型的训练速度。

3) 提出了改进的格拉姆角场图像化方法及基于 EfficientNetV2 的意图识别模型,充分利用了卷积神经网络的特征提取能力,同时实现了不同维度输入的接受和基于预训练模型的意图识别迁移学习,显著提升了模型的识别效果和适用性。

1 空中目标特征参数与作战意图

空中目标战术意图识别是一种典型的模式识别问题,它通过提取和分析战场环境信息、空战敌我

目标的静态属性和实时动态信息,将空战意图识别特征与空战意图类型相对应,从而实现对敌方目标作战意图的准确推断。这个过程需要利用各种传感器和数据融合技术,获取战场环境信息并提取出目标的特征。然后,通过分类器将这些特征映射到不同的空战意图类型上,最终得到敌方目标的战术意图。这种映射过程可以通过机器学习、深度学习等人工智能技术来实现,从而提高推断的准确性和效率。文献[9]在选取敌机意图特征时,考虑了多方面因素,最终选取了 12 种特征,包括敌机的高度、敌我距离、速度、加速度、航向角、方位角、雷达反射面积、敌机类型、对空雷达状态、对地雷达状态、机动类型和干扰状态。为了提高特征选择的必要性以及精细度,采用了时间曲线滤波技术,对特征进行了筛选。经过筛选,6 个高重要性特征被选出,分别是速度、敌机的高度、雷达反射面积、方位角、加速度和敌机类型。意图具体描述如表 1 所示,特征重要性排序如图 1 所示。

建立目标意图识别方法需要对意图类别进行明确定义和描述,即确定空战意图空间。将敌方目标的空战意图进行分类和定义,然后利用各种传感器和数据融合技术,获取战场环境信息并提取出目标的特征,通过分类器将这些特征映射到不同的空战意图类型上,最终得到敌方目标的战术意图。根据具体的实战背景、作战任务和作战模式,敌方目标可以有不同的空战意图。例如战争时期、冲突地区、战略要地等,作战意图空间则最可能为攻击、侦察、巡逻、掩护等。通过对这些方面的综合考虑,结合空域中战斗机目标意图识别问题,将敌机战术意图空间划分为攻击、警戒、干扰、佯攻、突防、侦察、撤退共 7 类,标签编码如图 2 所示。

表 1 意图特征具体描述

意图特征	描述	单位
速度	空中目标的飞行速度	m/s
敌机的高度	空中目标距离海平面的垂直距离	m
雷达反射面积	空中目标在雷达上的回波大小	m ²
方位角	我方军事建筑到空中目标方向的角度(正北时为 0,顺时针方向一周分为 6 400 mil)	mil
加速度	空中目标的飞行加速度	m/s ²
敌机类型	空中目标的种类及型号	国际民用航空组织(ICAO, international civil aviation organization)制定的飞机类型代码

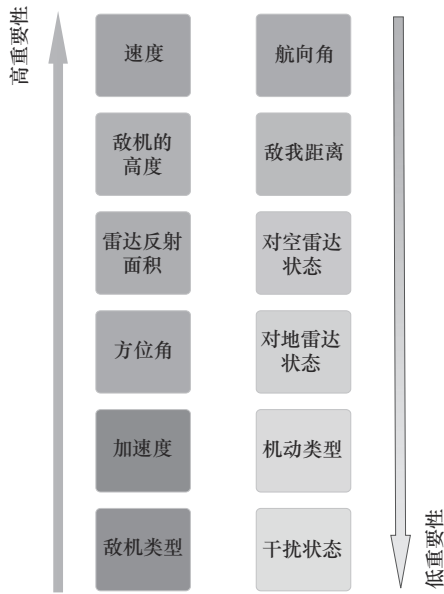


图 1 特征重要性排序




图 2 意图空间对应编码

为确保本文的严谨性并更准确地描述识别模型，做出以下假设：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；敌方空中

目标战术意图在所提取的时序中不发生改变^[5]。

2 意图识别模型描述

本文所提出的战术意图识别模型框架主要由 3 个核心部分构成：时序数据滤波、格拉姆角场编码以及 EfficientNetV2 识别。首先，在初始阶段，从包含众多特征的时序曲线中精确筛选出几个关键特征曲线。随后，采用经过优化的格拉姆角场技术，将这些经过滤波处理的时序数据编码为图像格式。最终，通过 EfficientNetV2 对编码后的时序图像进行高效识别。如图 3 所示，这 3 个环节在框架中紧密相连，形成了一个完整的处理流程。该框架不仅适用于多种识别模型，还展现出强大的跨平台移植能力。

2.1 时序数据滤波

深度学习模型强调其特征提取能力，可以学习从原始输入特征到结果的端到端映射关系。但冗余特征会对深度学习模型产生影响。最明显的问题是增加了模型的参数，导致过拟合，增加了模型训练的难度。虽然如正则化约束之类的训练技巧和技术可以解决这些问题，但安全有效地过滤候选特征显然是更好的方法。在意图识别过程中，敌机类型显然是最重要的变量，因为它直接表征了相关意图。例如，轰炸机执行的通常是攻击任务，而察打一体机则有可能执行侦察任务。此外，目标的速度和高度也是重要的特征，对于无人机而言，执行侦察和攻击任务时通常会采用不同的飞行高度和速度。对于作战仿真系统，其暂态仿真输出的可变维数非常

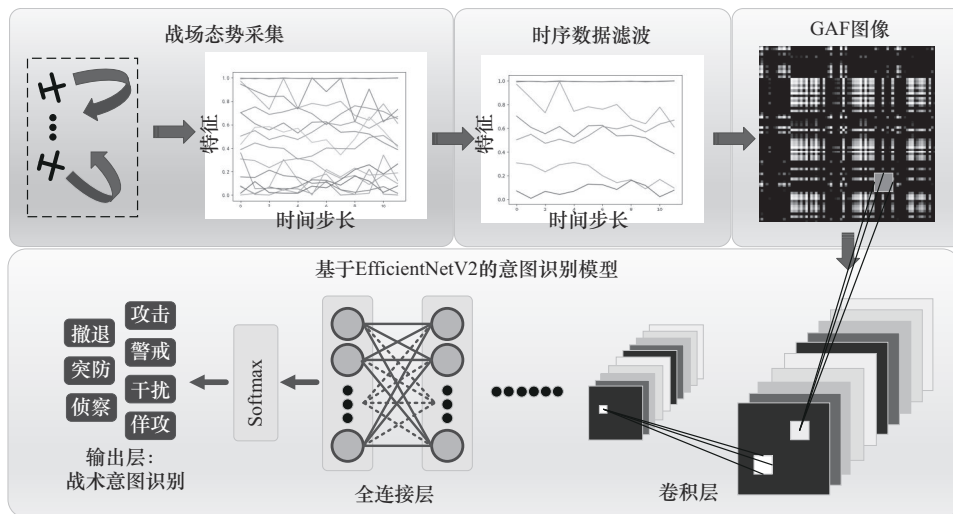


图 3 结合时序数据滤波和格拉姆角场的战术意图识别框架

高, 因此将它们全部输入到模型中进行训练显然是不合理的。

为了从大量仿真数据中选择相关特征并获取有意义的相关信息, 特征选择是关键方法之一, 可以去除不相关和冗余特征以更好地表示数据的策略。文献[28]提出了一种基于过滤器的特征选择技术, 使用标准差和均值与中位数之差进行特征选择。这种特征选择技术能够生成具有高辨识度和高偏差的简化特征子集。标准差、均值和中位数的应用在特征提取方面是有效的, 因为这些度量通过定量和统计推理来提取与分类相关的特征。特征的标准差可以被描述为一种统计度量, 用于度量特征与平均值的变异或偏差的数量。标准偏差可通过式(1)计算。

$$\sigma = \sqrt{\frac{\sum (x_i - \mu)^2}{N}} \quad (1)$$

其中, σ 为标准差, N 为样本总数, x_i 代表特征的各个值, μ 代表特征的均值。

均值和中位数可以定义为描述数据分布的描述性统计测度, 表示数据分布中偏差的相对大小。对于特征选择, 利用均值和中位数之差的绝对值从数据集中提取相关特征, 如式(2)所示。

$$D = |\text{Mean} - \text{Median}| \quad (2)$$

其中, D 表示给定特征的均值 (Mean) 与中位数 (Median) 之差的绝对值。对均值和中位数之差的解释表明, 较大的差值意味着在数据集中存在较大的偏差范围。因此, 选择具有较大差值的特征作为相关特征可以在预测和分类过程中提供有效性。特征选择过程如算法 1 所示。

算法 1 特征选择过程算法

输入 F 特征矩阵 (num_samples, num_features)

输出 initial_feature_set 初始特征子集索引列表, 默认为 None

#y: 目标变量/标签

#accuracy_func: 接收训练后的模型和测试数据, 返回准确率

#model_fit_func: 接收特征和目标变量, 训练模型并返回训练后的模型

计算标准差和均值与中位数之差的绝对值

std_devs = torch.std(F, dim=0)

means = torch.mean(F, dim=0)

medians = torch.median(F, dim=0).values

diffs = torch.abs(means-medians)

结合 2 种排序生成综合排序

```
combined_rank = (torch.argsort(std_devs, descending=True) + torch.argsort(diffs, descending=True)) + 1
```

初始化特征子集和最优准确率

```
current_feature_set = torch.tensor([], dtype=torch.long) if initial_feature_set is None else initial_feature_set
```

best_accuracy = 0.0

基于组合特征秩向特征子集添加特征, 并评估准确率

```
for feature_index in combined_rank do
```

```
  if feature_index not in current_feature_set do
```

```
    current_feature_set = torch.cat((current_feature_set, feature_index))
```

```
    selected_features = F[:, current_feature_set]
```

```
    trained_model = model_fit_func(selected_features, y)
```

```
    accuracy = accuracy_func(trained_model, selected_features, y)
```

```
    if accuracy > best_accuracy do
```

```
      best_accuracy = accuracy
```

```
    end if
```

```
  end if
```

```
end for
```

```
return initial_feature_set
```

2.2 改进的格拉姆角场图像化方法

Wang 等^[29]提出了一种常用的时序数据图像化算法, 即将一维时序数据转换为二维图像的格拉姆角场 (GAF, Gramian angular field) 算法。具体实现步骤如下: 假设时序为 $\mathbf{X} = \{x_1, x_2, \dots, x_i, \dots, x_N\}$, 包含 N 个观测值。首先, 对 \mathbf{X} 进行归一化, 使所有值都在 $[-1, 1]$ 或 $[0, 1]$ 范围内。归一化后的序列可以表示为

$$\tilde{x}_{-1}^i = \frac{(x_i - \max(\mathbf{X})) + (x_i - \min(\mathbf{X}))}{\max(\mathbf{X}) - \min(\mathbf{X})} \quad (3)$$

$$\tilde{x}_0^i = \frac{x_i - \min(\mathbf{X})}{\max(\mathbf{X}) - \min(\mathbf{X})} \quad (4)$$

然后将一维时序从笛卡尔坐标系转换为极坐标系, 可以表示为

$$\begin{cases} \phi_i = \arccos(\tilde{x}_i), -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X} \\ r_i = \frac{i}{N}, \quad i \in \mathbf{N} \end{cases} \quad (5)$$

在该算法中, 使用归一化观测值 \tilde{x}_i 的反余弦值

作为极坐标系下的角度 ϕ_i ，并以时间标号 $\frac{i}{N}$ 作为半径。2 种归一化操作处理的数据在转换为极坐标系时具有不同的角度范围。对于范围在 $[0, 1]$ 的数据，其对应的角度范围是 $\left[0, \frac{\pi}{2}\right]$ ；而对于范围在 $[-1, 1]$ 的数据，其对应的角度范围是 $[0, \pi]$ 。

这种基于极坐标系的表示方法提供了一种新的视角来理解时序。它将序列值随着时间的推移从原始的幅值变化转换为极坐标系下的角度变化。通过计算采样点之间三角函数的和或差，可以从角度的变化中识别出采样点之间的时间相关性。定义了格拉姆角和场 (GASF) 和格拉姆角差场 (GADF)，它们分别表示为

$$\mathbf{GASF} = \begin{bmatrix} \cos(\phi_1 + \phi_1) & \cdots & \cos(\phi_1 + \phi_n) \\ \cos(\phi_2 + \phi_1) & \cdots & \cos(\phi_2 + \phi_n) \\ \vdots & \ddots & \vdots \\ \cos(\phi_n + \phi_1) & \cdots & \cos(\phi_n + \phi_n) \end{bmatrix} \quad (6)$$

$$\mathbf{GADF} = \begin{bmatrix} \sin(\phi_1 - \phi_1) & \cdots & \sin(\phi_1 - \phi_n) \\ \sin(\phi_2 - \phi_1) & \cdots & \sin(\phi_2 - \phi_n) \\ \vdots & \ddots & \vdots \\ \sin(\phi_n - \phi_1) & \cdots & \sin(\phi_n - \phi_n) \end{bmatrix} \quad (7)$$

通过 GAF 算法，可以将一维时序数据转换为二维图像，这个转换过程包括缩放、坐标轴变换和三角函数 3 个步骤。这种转换将计算机视觉技术应用到时序研究中。图 4 所示为时序数据映射过程，展示了采用改进的格拉姆角场图像化方法将一维时序映射为二维图像的过程。

如图 4 所示，与文献[30]中 GAF 算法仅应用于单变量时序数据不同，本文提出了一种可以用于多特征时序数据的改进的格拉姆角场。由于不同特征维度的时序数据可能包含不同方面的信息，将多维时序特征顺序拼接在一起，可以将这些信息综合起来，提供更全面的特征表示。为了提高对于模型的适配度，将得到的单通道图像拓展为 RGB 三通道图像。图 5(a)和图 5(b)分别展示了由式(6)和式(7)得到的 GASF 和 GADF 三通道图像。

2.3 用于战术意图识别的 EfficientNetV2 模型

近年来，卷积神经网络的发展迅速^[31]，但也逐渐暴露出一些不足之处。卷积神经网络通常是在固定的资源预算下进行开发的。如果资源发生变化，例如网络深度、网络宽度、输入图像分辨率等都需要手动调整，这给科研工作带来了许多不便。

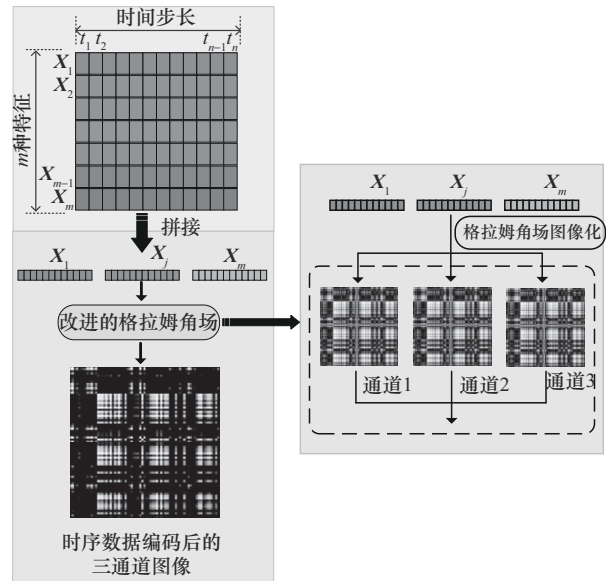




图 4 时序数据映射过程



(a) GASF



(b) GADF

图 5 GASF 和 GADF 图像化结果

为了解决这个问题，Tan 等^[32]在 2019 年首次提出了一种名为 EfficientNet 的高效网络。EfficientNet 利用一种简单高效的复合因子，从网络深度、网络宽度和输入图像分辨率这 3 个维度对网络进行缩放，而不是传统的任意缩放网络维度的方法。通过神经架构搜索技术^[33]得到最优的一组参数（综合系数）。根据缩放程度，EfficientNet 系列网络可以细分为 8 个子网络，命名为 $B_0 \sim B_7$ 。经过实际测试和验证，相比其他传统网络，EfficientNet 网络不仅速度更快，而且准确率也更高^[34]。

将 EfficientNetV2 应用于空中目标战术意图识别的动机在于其轻量级架构具有更快的推理时间、更快的训练速度和更少的参数。首先，它采用神经架构搜索神经架构搜索（NAS, neural architecture search）来同时优化模型的精度、大小和训练速度。其次，EfficientNetV2 网络还引入了 fuse-MBConv 块来提高操作强度并更好地利用移动设备或服务器加速器。然后，EfficientNetV2 架构广泛应用了 MBConv 和 fuse-MBConv 模块，以提高模型的训练速度和效率。如图 6 所示，在 fuse-MBConv 中，通过将 MBConv 中的深度 3×3 卷积和展开 1×1 卷积替换为规则的 3×3 卷积层，实现了模块的融合。研究表明，在 EfficientNetV2 中，使用 fuse-MBConv 块

替换部分 MBConv 块可以有效提升模型的训练速度和效率^[22]。EfficientNetV2 模型详细参数如表 2 所示。其中包括 fuse-MBConv 块，后续层采用具有 3×3 深度卷积的 MBConv 块，以及压缩和激励（SE, squeeze-and-excitation）块^[35]和 swish 激活函数。MBConv 块是一种反向剩余块，与 SE 块结合使用反向剩余连接，进一步提高性能。SE 块采用注意机制来增强特征表示，通过自学习权重确定图像区域的优先级。SE 块的结构如图 6 所示。网络使用 SiLU 激活函数作为激活函数，而不是 ReLU，因为它具有平滑的曲线，因此在梯度下降时更容易优化，相比于 ReLU 的硬饱和性质，SiLU 函数在接近零和负数时具有较小的梯度，这可以减少梯度消失的问题。

表 2 EfficientNetV2 模型参数

阶段	操作	步长	输入/输出通道数	层数
0	Conv 3×3	2	3/24	1
1	fuse-MBConv1, $k3 \times 3$	1	24/24	2
2	fuse-MBConv4, $k3 \times 3$	2	24/48	4
3	fuse-MBConv4, $k3 \times 3$	2	48/64	4
4	MBConv4, $k3 \times 3$, SE0.25	2	64/128	6
5	MBConv4, $k3 \times 3$, SE0.25	1	128/160	9
6	MBConv6, $k3 \times 3$, SE0.25	2	160/272	15
7	Conv 1×1 , pooling, FC	—	272/7	1

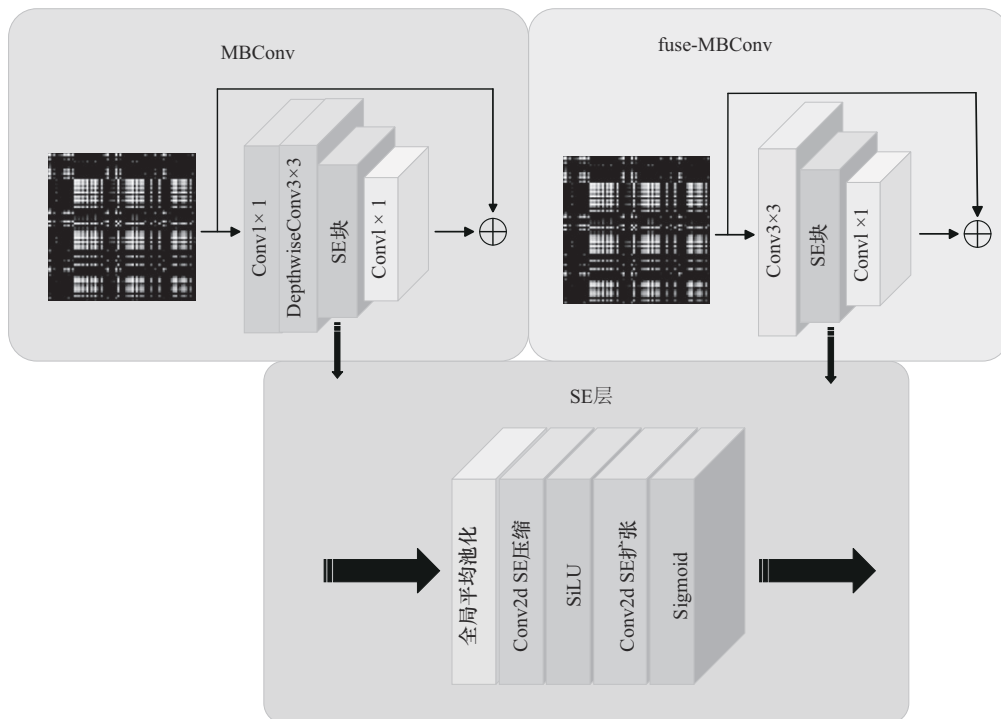


图 6 MBConv 和 fuse-MBConv 模块

3 实验分析

3.1 实验数据与环境

本实验的研究背景针对某空域作战场景进行,为了模拟真实的作战情况,使用了空战机动动作生成系统(ACMG, air combat maneuvering generator system)中的数据作为实验数据来源。通过运行仿真系统,获取了多种空战意图模式,并生成了210 000个空战意图样本。为进行后续的训练与测试,本研究采用了随机抽样方法。针对每种意图,均从总样本中随机选取12 800个样本,以保持各意图样本量一致。通过编程,利用随机数生成器实现了抽样的随机性与无偏性。最终抽取了89 600个空战意图样本,供后续训练和测试。每个样本采集了连续12帧信息,每帧信息包括航向角、飞行高度、干扰状态、雷达状态等12个维度特征信息。为了筛选出重要的特征信息,使用了时序数据滤波技术,最终选定了速度、敌机的高度、雷达反射面积、方位角、加速度和敌机类型6个特征。作战意图由飞行员、指挥官等空战领域专家进行标注,尽管过程中具有一定的主观性,但是专家丰富的实践经验,为后续模型训练和测试提供了重要的依据。数据集中包括7种目标战术意图,分别是攻击意图、突防意图、侦察意图、监视意图、佯攻意图、干扰意图和撤退意图,每个作战意图的数量各占14.3%。为了进行模型训练和测试,将样本集按照8:2的比例划分为训练集和测试集。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。数据集具体设置如表3所示。

表3 数据集设置

目标意图	样本总数/ 个	所占数据集 百分比	训练集样本 数/个	测试集样本 数/个
攻击	12 800	14.3%	10 240	2 560
突防	12 800	14.3%	10 240	2 560
侦察	12 800	14.3%	10 240	2 560
警戒	12 800	14.3%	10 240	2 560
佯攻	12 800	14.3%	10 240	2 560
干扰	12 800	14.3%	10 240	2 560
撤退	12 800	14.3%	10 240	2 560

实验使用了Python 3.9语言,并在NVIDIA GeForce 2080Ti GPU和CUDA 12.1加速环境下进行了实验。采用了Pytorch深度学习框架,并在x64-based PC系统、Intel® Core™ i5-13400F CPU @

2.50 GHz、32 GB内存的计算机上进行了实验。

3.2 性能评估指标

为了对所提出的战术意图识别框架的性能进行科学评估,采纳了5种不同的指标来对分类状况进行全面的衡量。这些指标分别是准确率(Accuracy)、损失值(Loss)、召回率(Recall)、精确率(Precision)和F1分数(F1-score)。准确率是分类正确的样本数量与总样本数量之比,用于衡量模型整体的分类性能。准确率越高,说明模型对于各类别的识别能力越强。损失值表示模型在训练过程中的损失函数值,用于衡量模型对于训练数据的学习程度。损失值越小,说明模型对于训练数据的拟合程度越好。召回率是被正确预测为正类别的样本数量与所有真正正类别的样本数量之比,用于衡量模型对于真正正类别的覆盖程度。召回率越高,说明模型能够更多地找出真正正类别的样本。精确率是被正确预测为正类别的样本数量与所有被预测为正类别的样本数量之比,用于衡量模型对于正类别的识别能力。精确率越高,说明模型对于正类别的识别能力越强。F1分数是精确率和召回率的调和平均值,综合考虑了精确率和召回率的表现。分别为

$$\text{Accuracy} = \frac{\sum_{r=1}^N X_r}{\sum_{r=1}^N X_r + \sum_{r=1}^N \sum_{l=1, l \neq r}^N Y_{r,l}} \quad (8)$$

$$\text{Loss} = -\frac{1}{M} \sum_{m=1}^M \sum_{n=1}^N p(x_{m,n}) \ln q(x_{m,n}) \quad (9)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (10)$$

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

$$\text{F1-score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (12)$$

其中, N 表示训练集中意图标签的总数, M 表示训练集中样本的总数, X_r 表示数据集中真实标签为 r 的样本中被正确分类的数量, $Y_{r,l}$ 则表示这些真实标签为 r 的样本中被错误分类为类别 l 的数量, $x_{m,n}$ 表示第 m 个样本中第 n 个元素或属于第 n 个类别的标记, TP为真正类, FN为假负类, FP为假正类。

3.3 实验参数设置

为了验证参数配置对模型的影响,选择优化器、批次大小(batch_size)、学习率(learning rate)和正则化参数(weight_decay)进行对比实验,并对测试的收敛性进行分析。图7展示了Efficient-

NetV2 参数配置对模型识别准确率的变化影响。

由图 7(a)可知, 优化器对战术意图识别效果具有显著影响, 直接影响模型的收敛速度、稳定性和最终性能。RMSprop 通过调整梯度的大小来加快收敛速度, 学习率过大, 导致收敛效果差。由于使用了学习率衰减策略, SGD 能够很好适应不同的训练阶段, 达到较好的收敛效果。Adam 及其变体结合了动量项和自适应学习率调整的优点, 通常能在各种任务上取得较好的性能。综合考虑, 选择 SGD 作为优化器。如图 7(b)所示, 批次大小的选择对于训练效率和模型性能具有显著影响。较大的批次能够利用并行计算资源, 从而加速模型的训练进程。然而这种加速往往以更高的内存需求为代价。此外, 过大的批次可能会限制模型的泛化能力, 因为它倾向于使优化过程陷入局部最优解, 而非追求全局最优解。当批次大小设定为 16 时, 模型在各项性能指标上表现最为优异。由图 7(c)可知, 当学

习率设置得偏大或偏小时, 模型的收敛效果和识别准确率均受到明显影响, 表现出较差的性能。这是因为过大的学习率可能导致模型在训练过程中跳过最优解, 而过小的学习率则可能使模型收敛速度极为缓慢, 甚至陷入局部最优解。当学习率被设定为 0.01 时, 模型展现出了更快的收敛速度和更高的识别准确率。由图 7(d)可知, 在没有正则化参数的情况下, 模型受到了过拟合影响, 导致在验证集上的表现较差。参数设置得过大时, 对模型权重施加了过强的惩罚, 导致模型无法学习到有效的特征表示, 从而严重影响了模型的性能。当参数设置为 0.000 1 时, 有助于抑制过拟合, 提高模型的泛化能力, 模型性能达到最佳。

3.4 实验结果与分析

为了证明使用 GAF 在瞬态过程中提取动态特征的效能, 提供了 7 个代表性的样本, 这些样本的图像局部特征差异显著, 如图 8 所示。如之前文献

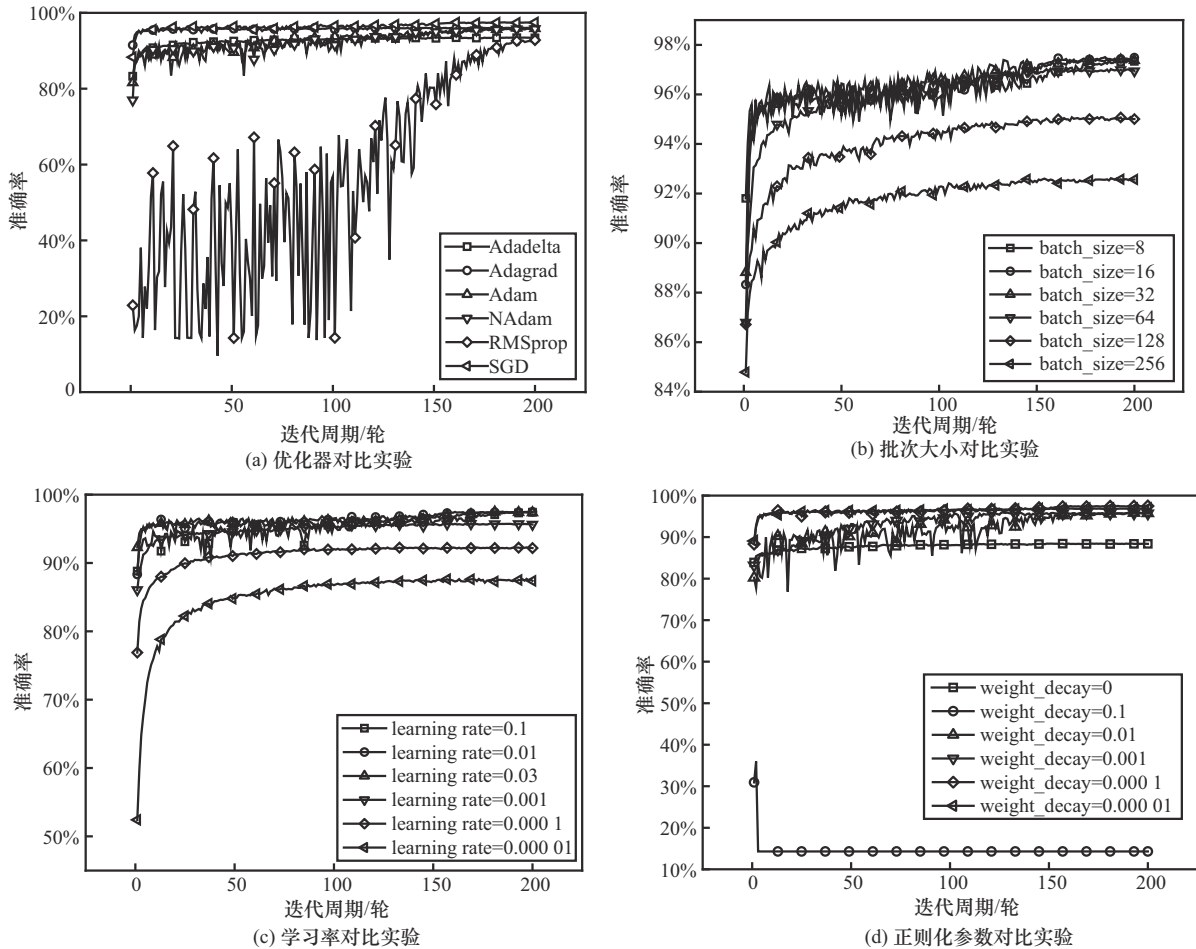


图 7 EfficientNetV2 参数配置对模型识别准确率的变化影响

所述, CNN 在图像识别领域的优势主要在于其出色的局部特征挖掘能力。因此, 利用 GAF 变换得到的意图图像可以提供更准确的判断结果。也就是说, 通过 GAF 对空中目标的暂态过程进行特征变换, 可以保持不同类别之间的样本可变性, 使其更适合于 CNN 的处理。

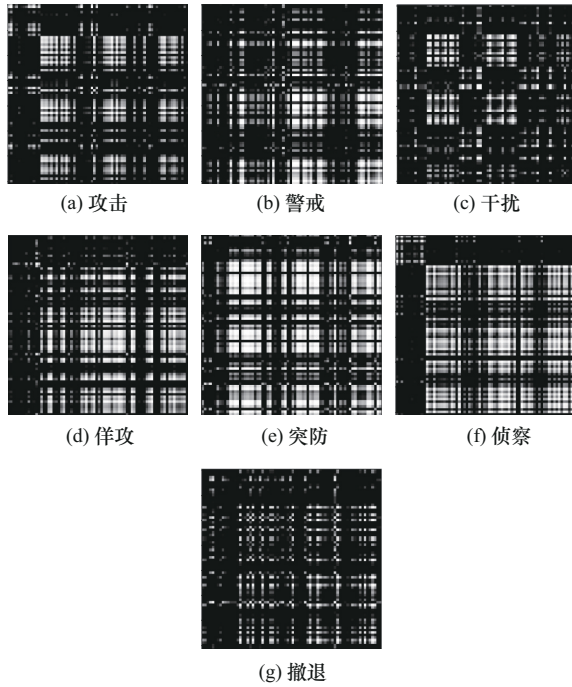


图 8 不同样本的 GAF 图像

3.4.1 EfficientNetV2 实验结果

EfficientNetV2 经过在数据集中训练, 得到了如图 9 所示的实验结果。在训练的过程中, 模型的准确率随着训练轮数的增加而逐渐提升, 同时损失值也在逐渐下降。经过 150 轮的训练后, 模型已经趋于收敛。在应用 GADF 的情况下, 模型在测试集上的准确率最高达到了 97.09%, 而损失值最低则达到了 0.128。而在应用 GASF 的情况下, 模型在测试集上的准确率最高达到了 97.51%, 损失值最低为 0.111。这一结果表明, 模型在新的数据集上展现出了强大的泛化能力, 可以有效地学习数据集中的特征, 并且能够精准地识别空中目标的战术意图。如表 4 所示, 在对 7 种意图的分类中, 除了警戒意图与撤退意图的精确率稍低外, GASF 在其余 3 种指标上均表现出优于 GADF 的性能。这一优势源于 GASF 通过计算格拉姆矩阵和角度场生成图像表示, 这种处理方式使得该方法能够有效地捕获时序数据中的长期依赖关系及周期性模式。相比之

下, GADF 则通过计算时序的一阶或二阶差分来生成图像, 更侧重于捕捉数据的局部变化和短期模式。因此, 对于具有复杂长期依赖性和周期性模式的数据集, GADF 可能无法全面捕捉到这些数据中的重要特征, 从而导致其性能受到限制。

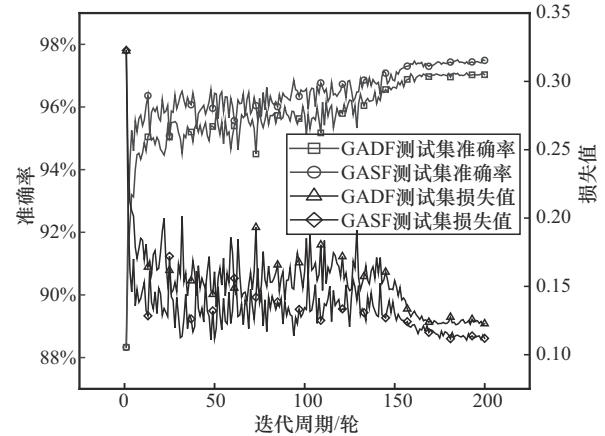


图 9 实验结果

表 4 意图识别性能度量

目标意图	精确率		召回率		F1 分数	
	GADF	GASF	GADF	GASF	GADF	GASF
攻击	97.21%	97.53%	96.52%	97.33%	96.86%	97.38%
警戒	96.39%	96.26%	95.98%	96.36%	96.18%	96.26%
干扰	97.09%	97.96%	97.62%	97.68%	97.35%	97.77%
佯攻	96.54%	97.12%	96.91%	97.50%	96.73%	97.31%
突防	96.44%	97.15%	97.23%	97.58%	96.83%	97.56%
侦察	96.62%	97.88%	96.05%	97.20%	96.34%	97.54%
撤退	98.71%	98.67%	98.67%	98.92%	98.69%	98.75%

3.4.2 不同时序方法对比实验

为了验证本文提出的基于 EfficientNetV2 的意图识别模型在战术意图识别任务中的性能, 综合对比了包括传统机器学习模型在内的多种算法。所选用的对比模型包括原始主干模型 EfficientNet^[19]、经典的 CNN^[20]、残差神经网络 (ResNet18)^[21]、视觉几何组 (VGG, visual geometry group) 网络^[22]、支持向量机 (SVM, support vector machine)^[14]、多层感知机 (MLP, multilayer perceptron)^[15]、RNN^[16]、GRU^[17]、LSTM 网络^[18], 以及基于最新研究成果的模型, 如 BiLSTM-Attention 模型^[6]、层次聚合模型 Hierarchical Aggregation model^[7]、Attention-TCN-BiGRU 模型^[8]、BiGRU-FCN 模型^[9]、采用 Adam 优化器和 ReLU 激活函数改进的 DBP 模型^[10]、BiGRU-Attention 模型^[11]、

BiLSTM-TCN 模型^[12], 以及 Transformer 模型^[13]。在这些模型中, EfficientNet使用的是B₀配置, CNN作为基准模型, 其结构简单, 由3个带池化操作的卷积层和2个全连接层组成, 且不包含MBConv和fuse-MBConv模块。LSTM网络、GRU和RNN均采用了双层架构。SVM则采用了高斯核函数。对于其他机器学习模型, 并未遵循各自文献中推荐的默认参数配置, 而是重新调试参数, 确保网络性能最佳。实验结果如表5所示。从表5可以看出, EfficientNetV2模型的性能远远优于其他机器学习模型, 比原始主干模型EfficientNet提高了1.48%的准确率, 比CNN提高了5%以上的准确率, 比浅层机器学习方法提高了2%~12%的准确率。

表5 不同模型的测试结果

模型	准确率	精确率	召回率	F1分数
EfficientNetV2 ^[34]	97.51%	97.46%	97.42%	97.54%
EfficientNet ^[19]	96.03%	96.02%	96.06%	96.02%
CNN ^[20]	91.89%	91.82%	91.67%	91.77%
ResNet18 ^[21]	95.08%	95.09%	95.03%	95.01%
VGG ^[22]	95.63%	95.63%	95.63%	95.63%
SVM ^[14]	83.88%	83.79%	83.84%	83.80%
MLP ^[15]	90.15%	89.99%	90.15%	90.14%
RNN ^[16]	93.54%	93.55%	93.49%	93.50%
GRU ^[17]	94.65%	94.60%	94.63%	94.57%
LSTM ^[18]	94.57%	94.58%	94.57%	94.57%
BiLSTM-attention ^[6]	95.92%	95.91%	95.88%	95.89%
Hierarchical Aggregation model ^[7]	95.71%	96.72%	96.70%	96.66%
Attention-TCN-BiGRU ^[8]	96.41%	96.40%	96.41%	96.40%
BiGRU-FCN ^[9]	96.0%	96.0%	95.86%	96.0%
DBP ^[10]	95.57%	95.28%	95.57%	95.57%
BiGRU-Attention ^[11]	96.52%	96.53%	96.50%	96.47%
BiLSTM-TCN ^[12]	96.38%	96.39%	96.27%	96.38%
Transformer ^[13]	90.09%	90.15%	90.95%	90.11%

3.4.3 非平衡数据集对比实验

为了验证该框架的跨系统可扩展性及其实战效用, 更全面地评估框架在各种实际情况下的性能表现, 采用了空战机动测试 (ACMI, air combat maneuvering instrumentation) 系统生成的数据进行测试。非平衡数据集具体设置如表6所示。与ACMG系统相比, ACMI系统在生成样本时更加贴近真实的作战场景, 针对每种作战意图都生成了不同数量的样本, 总计达到了3 513个。

表6 非平衡数据集具体设置

目标意图	标签	总样本数/个	训练集样本数/个	测试集样本数/个
攻击	0	267	214	53
侦察	1	282	226	56
干扰	2	603	482	121
佯攻	3	518	414	104
突防	4	465	372	93
监视	5	714	571	143
撤退	6	664	531	133

本文提出的战术意图识别框架与其他机器学习方法的对比结果如表7所示。本文提出的识别框架仍保持了最好的性能, 达到了高达98.86%的准确率。此外, 该框架在准确率、召回率和F1分数表现出的一致性, 证明了其在处理数据不均衡问题上相较于其他机器学习模型的优越性。

表7 战术意图识别框架与其他机器学习方法的对比结果

模型	准确率	精确率	召回率	F1分数
EfficientNetV2 ^[34]	98.86%	98.89%	98.88%	98.89%
EfficientNet ^[19]	98.43%	98.33%	98.57%	98.32%
CNN ^[20]	98.29%	98.36%	98.17%	98.26%
ResNet18 ^[21]	98.43%	98.54%	98.57%	98.55%
VGG ^[22]	98.29%	98.33%	98.36%	98.32%
SVM ^[14]	75.24%	81.15%	78.32%	72.91%
MLP ^[15]	88.78%	88.05%	91.34%	88.75%
RNN ^[16]	89.63%	88.64%	91.86%	89.34%
GRU ^[17]	89.63%	88.49%	92.45%	89.33%
LSTM ^[18]	90.62%	89.47%	92.96%	90.43%
BiLSTM-Attention ^[6]	96.59%	94.75%	96.38%	95.48%
Hierarchical Aggregation model ^[7]	95.31%	94.10%	95.66%	94.70%
Attention-TCN-BiGRU ^[8]	95.17%	93.13%	95.63%	94.14%
BiGRU-FCN ^[9]	97.59%	96.30%	97.38%	96.74%
DBP ^[10]	90.62%	88.44%	92.49%	89.84%
BiGRU-Attention ^[11]	95.88%	94.02%	96.44%	94.85%
BiLSTM-TCN ^[12]	94.32%	92.80%	95.30%	93.31%
Transformer ^[13]	97.02%	95.96%	97.23%	96.42%

图10展示了使用时序数据滤波技术前后的模型准确率变化。从图10可以看出, 时序数据滤波技术在处理时序数据时能够有效地去除噪声和冗余信息, 使得模型能够更加专注于学习关键特征, 大多数模型的表达能力得到了增强, 进而提升了分类的准确率。

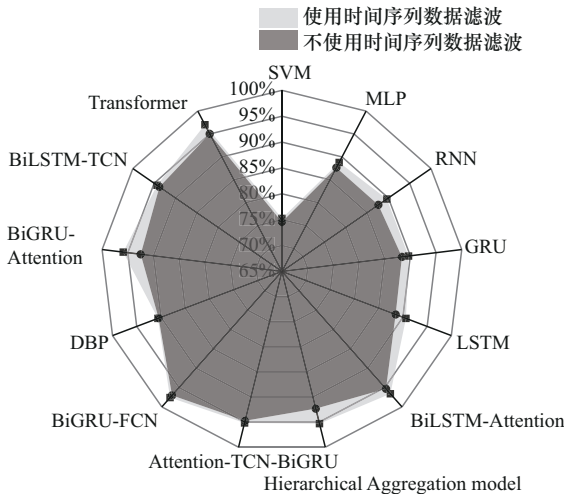



图 10 不同方法在 ACMI 数据上的准确率

在战术意图识别中, 计算效率尤其关键, 它不仅直接关系到对计算机硬件的性能需求, 还显著影响着模型的训练速度。本文引入了时序数据滤波方法, 有效地降低了输入到模型中的特征维度, 从而大幅提升训练效率。图 11 直观地展示了不同方法在 ACMI 数据上的训练时间。显然, 若不对特征进行有针对性的过滤处理, 模型的计算负担将显著增加, 进而降低整体效率。通过应用时序数据滤波方法, 本文提出的框架在保持高性能的同时, 也显著优化了计算资源的利用, 为实际应用部署提供了有力支持。



(a) 使用时序数据滤波

3.4.4 模型鲁棒性分析


尽管之前的实验已经充分证明了本框架在给定数据集上的卓越性能, 但模型的鲁棒性同样是一个不容忽视的问题。在实际战场环境中, 由于敌机的干扰以及复杂多变的战场条件, 传感器采集的数据往往存在误差和噪声。这些因素都可能导致训练样本集与实际运行环境之间的差异, 进而使得训练集和测试集的数据分布不一致。数据分布的不一致性是机器学习模型性能下降的关键因素之一。为了验证本框架在鲁棒性方面的优势, 对数据集添加了不同信噪比的高斯白噪声。根据式(13)~式(15)计算信号的信噪比 (SNR, signal to noise ratio)。

$$SNR = 10 \lg \frac{P_{\text{signal}}}{P_{\text{noise}}} = 10 \lg \frac{\sum x^2}{\sum n^2} \quad (13)$$

$$|n| = \frac{\sum x^2}{N \cdot 10^{\frac{SNR}{10}}} \quad (14)$$

$$\text{noise} = \text{random}(N) \cdot \sqrt{|n|} \quad (15)$$

其中, 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 和 -20 dB 的情况下选择了 CNN、SVM 以及使用曲线滤波特 SVM 进行对比实验。模型鲁棒性测试结果如图 12 所示。



(b) 不使用时序数据滤波

图 11 不同方法在 ACMI 数据上的训练时间




图 12 模型鲁棒性测试结果

从图 12 中可以清晰地看出，EfficientNetV2 在鲁棒性方面显著优于其他对比模型。在 7 种不同的测试场景下，绝大多数指标均保持最高。此外，使用曲线滤波特征的支持向量机模型相较于使用原始特征的支持向量机模型展现出了更好的鲁棒性，这表明经过滤波处理的特征具有更强的泛化能力。

为了更直观地解释框架泛化能力的原因，采用 t-SNE 技术对场景的不同输入特征进行了可视化处

理，相关结果如图 13 所示。随着特征的不断优化，不同样本之间的差异逐渐缩小，这一现象很好地解释了框架鲁棒性的原因。

3.4.5 不同模拟系统的迁移学习

在本文提出的战术意图识别模型中，主要处理的是图像输入，尽管不同的仿真系统在特征表现上存在差异，但通过在大型仿真系统数据上预训练模型，能够利用微调技术使其适应其他小型系统。大

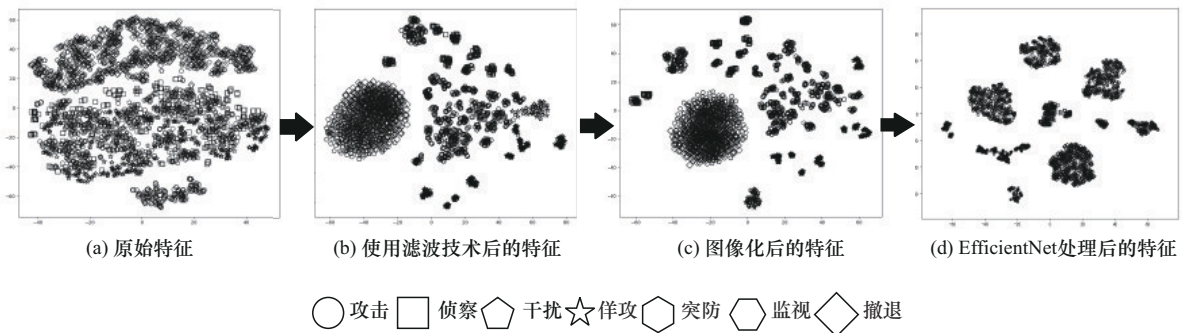


图 13 t-SNE 降维处理结果

型仿真系统通常涵盖更广泛的场景和更多的样本, 这为预训练模型提供了丰富的特征学习机会。在微调过程中, 冻结 EfficientNet 中的卷积网络部分, 仅对全连接层进行微调。这样做的好处是在微调阶段, 卷积层不需要进行梯度下降计算, 从而显著节省了 GPU 内存和训练时间。这种微调策略的有效性基于迁移学习的 2 个基本前提: 源域和目标域之间的相似性, 以及预训练模型的全面性和泛化能力。

为了验证微调的效果, 在 ACMG 系统预训练的模型上进行了实验, 将其迁移到 ACMI 系统, 并仅使用了 3 000 个样本进行微调, 结果如图 14 所示, 微调后的模型在准确性上稍逊于从头开始训练的模型, 但在计算资源消耗上却大大减少。此外, 本文还比较了不同训练样本数量下 2 种训练方法的准确率, 如图 15 所示, 发现在样本数量有限的情况下, 微调方法具有明显优势。




图 14 从头开始训练和微调的准确率




图 15 不同样本数量下的 2 种训练方式准确率

这些结果表明, 通过微调预训练模型, 可以在不同系统之间实现有效的迁移学习。这不仅提高了模型的适应性和泛化能力, 还大大降低了训练成本和时间。可以预见的是, 如果预训练模型足够强大(即用尽可能多的样本进行训练), 微调的效果将会更加显著。因此, 在其他更简单的场景中, 迁移学习无疑是一种更简单、更有效的策略。

4 结束语

针对战场复杂数据分析难的问题, 本文构建了一个高效的战术意图识别模型。该模型主要由 3 个部分构成: 时序数据滤波、格拉姆角场编码以及 EfficientNetV2 识别。首先采用先进的时序数据滤波技术, 大量地减少了数据中的特征冗余, 进而提升模型的分类准确性。运用改进后的格拉姆角场图像化方法, 将经过滤波处理的时序数据转换为图像, 让模型能够有效地捕捉时序中的动态特征, 使其更适合 CNN 进行局部特征的提取。在模型的核心部分, 引入了 EfficientNetV2 网络, 该网络不仅具有很强的特征提取能力还具备作为预训练模型的潜力。通过与多种机器学习方法进行对比实验发现, 本文所提出的战术意图识别模型在综合性能上表现最佳。在 ACMI 系统上对预训练模型进行了微调实验, 结果显示, 微调后的模型能够快速适应新的系统环境, 并且在训练样本、GPU 内存和训练时间方面都实现了显著的节省, 这意味着在未来的研究中, 可以利用该模型进行迁移学习, 从而加速新任务的训练过程。

参考文献:

- [1] XIA J Y, CHEN M Q, FANG W G. Air combat intention recognition with incomplete information based on decision tree and GRU network[J]. Entropy, 2023, 25(4): 671.
- [2] 李磊, 韩洪伟, 蒋琪. 美决策中心战概念研究[J]. 战术导弹技术, 2021(1): 34-37, 120.
LI L, HAN H W, JIANG Q. Analysis of the concept of U.S. Decision-centric warfare[J]. Tactical Missile Technology, 2021(1): 34-37, 120.
- [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] GENG J, DENG X Y, MA X R, et al. Transfer learning for SAR image classification via deep joint distribution adaptation networks[J]. IEEE

- Transactions on Geoscience and Remote Sensing, 2020, 58(8): 5377-5392.
- [5] TENG F, GUO X P, SONG Y F, et al. An air target tactical intention recognition model based on bidirectional GRU with attention mechanism [J]. IEEE Access, 2021, 9: 169122-169134.
- [6] 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.
- [7] 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.
- [8] TENG F, SONG Y F, GUO X P. Attention-TCN-BiGRU: an air target combat intention recognition model[J]. Mathematics, 2021, 9(19): 2412.
- [9] 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 (24): 171-186.
- DING P, SONG Y F. Cost-sensitive airborne target intent recognition method[J]. Journal of Aeronautics, 2023(24): 171-186.
- [10] 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): 195-203.
- 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): 195-203.
- [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(1): 1-13.
- [12] SHIKALGAR M B, ARAGE C S. Fake news detection using hybrid BiLSTM-TCN model with attention mechanism[C]//Proceedings of the 2023 2nd International Conference on Applied Artificial Intelligence and Computing (ICAIC). Piscataway: IEEE Press, 2023: 1130-1136.
- [13] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. Advances in Neural Information Processing Systems, 2017, 30 (1): 5998-6008.
- [14] CORTES C, VAPNIK V. Support-vector networks[J]. Machine Learning, 1995, 20(3): 273-297.
- [15] ROSENBLATT F. The perceptron: a probabilistic model for information storage and organization in the brain[J]. Psychological Review, 1958, 65(6): 386-408.
- [16] ELMAN J L. Distributed representations, simple recurrent networks, and grammatical structure[J]. Machine Learning, 1991, 7(2): 195-225.
- [17] CHO K, MERRIENBOER B V, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[J]. arXiv Preprint, arXiv: 1406.1078, 2014.
- [18] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [19] TAN M X, LE Q V. EfficientNet: rethinking model scaling for convolutional neural networks [J]. arXiv Preprint, arXiv: 1905.11946, 2019.
- [20] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [21] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2016: 770-778.
- [22] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv Preprint, arXiv: 1409.1556, 2014.
- [23] KUANG X, HE J, HU Z, et al. Comparison of deep feature learning methods for human activity recognition[J]. Applied Research in Computing, 2018, 35(9): 2815-2817.
- [24] SHI Z T, YAO W, ZENG L K, et al. Convolutional neural network-based power system transient stability assessment and instability mode prediction[J]. Applied Energy, 2020, 263: 114586.
- [25] AZMAN S K, ISBEIH Y J, EL MOURSI M S, et al. A unified online deep learning prediction model for small signal and transient stability[J]. IEEE Transactions on Power Systems, 2020, 35(6): 4585-4598.
- [26] ZHANG R Y, WU J Y, XU Y, et al. A hierarchical self-adaptive method for post-disturbance transient stability assessment of power systems using an integrated CNN-based ensemble classifier[J]. Energies, 2019, 12 (17): 3217.
- [27] ZHANG R F, YAO W, SHI Z T, et al. Encoding time series as images: a robust and transferable framework for power system DIM identification combining rules and VGGNet[J]. IEEE Transactions on Power Systems, 2023, 38(6): 5781-5793.
- [28] THAKKAR A, LOHIYA R. Fusion of statistical importance for feature selection in Deep Neural Network-based Intrusion Detection System[J]. Information Fusion, 2023, 90: 353-363.
- [29] WANG Z, OATES T. Imaging time-series to improve classification and imputation[J]. arXiv Preprint, arXiv: 1506.00327, 2015.
- [30] ALSALEMI A, AMIRA A, MALEKMOHAMADI H, et al. Lightweight Gramian angular field classification for edge Internet of energy applications[J]. Cluster Computing, 2023, 26(2): 1375-1387.
- [31] SHIN H C, ROTH H R, GAO M C, et al. Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning[J]. IEEE Transactions on Medical Imaging, 2016, 35(5): 1285-1298.
- [32] TAN M X, CHEN B, PANG R M, et al. MnasNet: platform-aware neural architecture search for mobile[C]//Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2019: 2815-2823.
- [33] DENG L W, SUO H F, LI D J. Deepfake video detection based on

EfficientNet-V2 network[J]. Computational Intelligence and Neuroscience, 2022(1): 1-13.

[34] TAN M X, LE Q V. EfficientNetV2: smaller models and faster training [J]. arXiv Preprint, arXiv: 2104.00298, 2021.

[35] RAMACHANDRAN P, ZOPH B, LE Q V. Searching for activation functions[J]. arXiv Preprint, arXiv: 1710.05941, 2017.

[作者简介]




宋亚飞 (1988-), 男, 河南汝州人, 博士, 空军工程大学教授、博士生导师, 主要研究方向为模式识别、智能信息处理、网络空间安全。



李乐民 (1999-), 男, 重庆人, 空军工程大学硕士生, 主要研究方向为智能信息处理、态势感知。



权文 (1988-), 女, 陕西蒲城人, 博士, 空军工程大学讲师, 主要研究方向为机器学习及其在空管领航、目标识别等领域的应用。



倪鹏 (1985-), 男, 福建福州人, 博士, 复杂航空系统仿真重点实验室工程师, 主要研究方向为作战建模与仿真。



王科 (1999-), 男, 重庆人, 空军工程大学硕士生, 主要研究方向为模式识别、态势感知。