

基于迁移学习与运动特征融合的机型分类识别方法

葛成龙, 张 静, 杜剑平, 吴 优

(信息工程大学, 河南 郑州 450001)

摘要: 针对当前高精度标注数据稀缺、难以有效支撑模型训练, 进而导致机型分类准确率低的问题, 提出一种基于迁移学习与运动特征融合的机型分类识别方法。首先, 分析不同类型飞行器的运动特性差异; 其次, 用 RGB 算法将运动差异化特征转化为同时蕴含轨迹形状信息与目标运动属性的轨迹图像; 最后, 针对小样本数据场景, 引入迁移学习策略, 基于预训练 ResNet 模型进行微调优化, 完成机型分类识别。实验结果表明, 所提方法在小样本数据集下取得了 75.6% 的机型分类准确率, 相比基线模型准确率提升了 11~15.3 个百分点。

关键词: 机型分类识别; 广播式自动相关监视系统; RGB 算法; 联合运动特征; 迁移学习

中图分类号: TP391.4

文献标识码: A

文章编号: 1671-0673(2026)01-0056-08

A Method for Aircraft Model Classification Based on Transfer Learning Combined with Motion Features

GE Chenglong, ZHANG Jing, DU Jianping, WU You

(Information Engineering University, Zhengzhou 450001, China)

Abstract: To address the issue of low aircraft classification accuracy caused by the scarcity of high-precision labeled data, which hinders effective model training, an aircraft classification and recognition method based on transfer learning and motion feature fusion is proposed. Firstly, differences in motion characteristics of different types of aircraft are analyzed. Subsequently, the RGB algorithm is employed to transform motion-differentiated features into trajectory images that encapsulate both trajectory shape information and target motion attributes. Finally, for scenarios with limited sample data, a transfer learning strategy is introduced, fine-tuning and optimizing a pre-trained ResNet model to accomplish aircraft model classification and recognition. Experimental results demonstrate that the proposed method achieves an aircraft model classification accuracy of 75.6% on small-sample datasets, outperforming baseline models by an improvement of 11 to 15.3 percentage points.

Key words: aircraft model classification; automatic dependent surveillance broadcast system; RGB algorithm; joint motion features; transfer learning

随着航空运输业的蓬勃发展和现代战争形态的演变, 精准识别飞行目标机型, 对空域容量评估、航路规划、飞行间隔标准制定、冲突探测与解脱以及异常行为监测等关键任务的效能具有直接影响, 对确保空域安全、提升运行效率及实现精细化空中交通管理(Air Traffic Management, ATM)具

有至关重要的意义。特别是在军事领域, 由于空中目标种类和数量的激增以及飞行速度的提升, ATM系统的处理负荷显著增加, 同时对目标识别的准确性和时效性也提出了前所未有的更高要求。因此, 精确的飞机机型识别作为情报指挥系统中目标识别的关键组成部分, 对于后续威胁评

估、火力资源优化配置乃至最大化整体作战效能,发挥着不可或缺的作用。

早期研究主要聚焦从广播式自动相关监视系统(Automatic Dependent Surveillance Broadcast System, ADS-B)轨迹中挖掘基础特征。通过人工设计特征工程^[1],从连续轨迹数据中提取速度、加速度等统计量,并结合传统机器学习算法,完成轨迹与机型的映射关系建模^[2]。该方法虽在一定程度上实现了机型分类,但高度依赖人工特征设计经验,且难以捕捉轨迹数据中隐含的复杂时空模式。

近年来,学者们尝试用深度学习技术从轨迹数据中挖掘特征,对飞机机型进行分类。Endo等^[3]利用深度网络的特征提取能力,首次将轨迹数据转化为图像,将轨迹停留时间以像素深浅的方式表示出来,并将结合时间与空间双重特征的轨迹图片送入卷积神经网络(Convolutional Neural Network, CNN),达到了较好的分类效果。Kontopoulos等^[4]提出了将空间归一化的方法,同时对速度色彩编码,以加强轨迹图片的表达能力。Chen等^[5]将目标运动定义为3种状态,计算出这3种状态并以3种颜色叠加到轨迹图像上,最后利用CNN进行图片识别,达到了较好的分类效果。Lu等^[6]通过计算轨迹中的运动信息,将特征转换为递归图,使用双层卷积编码器进行分类。王哲等^[7]将轨迹数据中的经纬度、航速、航向转换为Four-hot编码,然后送入Transformer-LSTM进行特征提取,最后对特征进行分类。He等^[8]首先提取轨迹中的时空特征,之后基于图片匹配技术提取轨迹图像的形状特征,最后将两种特征进行聚类,达到目标分类的目的。

然而,当前基于轨迹图像化的机型识别方法存在显著的技术局限性。首先,现有轨迹可视化方法虽引入RGB编码,但其色彩主要服务于增强视觉对比度或区分离散状态,颜色与连续运动物理量间缺乏直接、统一的语义关联,导致图像特征与运动属性间的语义鸿沟依然存在。其次,现有数据驱动方法普遍依赖大规模标注数据集的深度学习范式,在低标注量场景下,模型易陷入过拟合困境,导致分类准确率显著下降。

针对以上问题,提出一种基于迁移学习与运动特征融合的机型分类识别方法。主要实现以下内容:1)运动特征与轨迹图像的语义化融合。摒弃传统仅用于视觉增强的色彩编码思路,提出一种将速度、加速度、航向变化率等连续运动物理量直接、统一地映射至RGB色彩空间的算法。该方法构建的轨迹图像同时蕴含目标的几何形状与连


续运动状态信息,实现了运动特征与视觉特征的深度语义关联。2)面向小样本场景的迁移学习微调策略。针对高精度标注数据稀缺的挑战,设计一种渐进式微调策略。基于预训练的ResNet模型,通过系统分析网络层特征的可迁移性,采用“冻结底层、解冻高层”的优化方式,有效克服了小样本条件下的过拟合问题,显著提升了模型的泛化能力。3)多层次验证的实验设计与可靠性分析。不仅通过对比实验验证了方法的性能优势,还引入类激活映射(Class Activation Mapping, CAM)等技术对模型决策依据进行可视化分析,证实了网络关注区域与关键判别特征的一致性,从性能提升与决策机理两个维度共同验证了方法的有效性与可靠性。

实验结果表明,在样本规模较小且航迹信息仅包含速度、航向、经纬度等少量关键参数的小信息量场景下,本文方法的分类识别准确率最高为75.6%;相比于基线模型,识别准确率提升11~15.3个百分点,验证了其在低标注量场景下进行飞行目标机型分类识别的可行性与有效性。

1 问题描述

当前广泛应用的ADS-B数据虽提供了飞机的实时位置(经纬度)、速度、航向等关键参数,但其数据维度低、信息量有限,且原始离散的点序列难以被深度学习模型(如CNN)直接有效利用。

飞行轨迹本身是时空位置序列在空间描绘出的曲线,天然具有图像轮廓属性。不同机型因其设计目的和性能差异,飞行轨迹呈现显著不同的运动特征。不同机型的动态运动参数也存在较大区别,主要体现在速度剖面、航向变化率、垂直速率及整体轨迹形态上。例如,大型客机速度高且稳定、转弯平缓、轨迹规律;小型通用飞机速度变化范围小、相对机动灵活;军用飞机则可能表现出高速、急转弯等剧烈机动模式。不同机型归一化运动轨迹如图1所示。






图1 不同机型的运动轨迹图

因此,可以利用这些差异性,将飞行轨迹及其蕴含的运动特性建模为图像,使原本抽象的运动特征转化为CNN擅于识别的视觉模式(如图像纹理、颜色梯度),同时还可以克服数据形式的限制。

2 本文方法

基于迁移学习与运动特征融合的机型分类识别方法总体流程主要包含3个部分:首先,对航迹数据集进行清洗、降噪和插值等操作,提取出航迹数据的运动特征;其次,运用RGB算法构建轨迹图像;最后,构建ResNet预训练模型,运用图像数据对模型各层进行依次微调,并通过最终的映射识别层实现机型分类判别。

2.1 轨迹数据清洗与运动特征提取

在进行轨迹图像构建之前,需对原始ADS-B数据进行预处理。首先,对轨迹数据进行清洗、降噪与插值,以获得连续、完整的航迹序列,从而确保数据质量。随后,从中提取速度、加速度和航向变化率等关键运动特征,并分析其分布差异,验证不同机型在飞行行为上的可区分性,为轨迹图像的颜色编码提供判别依据。

2.1.1 轨迹数据的清洗、降噪和插值

本文对OpenSky网站^[9]提供的数据进行清洗、重建和插值,得到位置点连续且长度适合模型训练的轨迹,数据预处理的步骤如下。

1)对比OpenSky网站提供的飞机型号与呼号

的关系,并根据经纬度范围对数据进行过滤,得到带有飞机型号标签的轨迹数据。

2)选用4个与空间信息相关的参数:经度、纬度、速度和航向。可以将轨迹表示为集合 $T_{\text{traj}} = \{p_1, p_2, p_3, \dots, p_n\}$,其中, n 为采样点的总数。对于 $\forall p \in T_{\text{traj}}, p_t = \{R_{\text{lat}}^t, R_{\text{lon}}^t, R_{\text{velocity}}^t, R_{\text{heading}}^t\}$, t 为飞行器轨迹的采样时间点, R_{lat}^t 、 R_{lon}^t 、 R_{velocity}^t 、 R_{heading}^t 分别表示纬度、经度、速度和航向在时间 t 的采样点。

3)轨迹数据清洗与重建。首先,从ADS-B数据中剔除和过滤无效值,包括经纬度相同点和相邻两点之间的缺失值。其次,去除噪声轨迹,将少于30个轨迹点的轨迹作为噪声数据进行删除。最后,采用基于距离的轨迹重建方法进行轨迹重建,设置阈值为30 km。如果两个相邻点之间的距离超过阈值,则将其标记为间断点,如果相邻间断点的数据点数大于30,则将两个间断点之间的轨迹保存为一条新的轨迹。

4)线性插值补全缺失的数据。ADS-B数据的接收时间间隔设定为 Δt ,本文取10 s。相邻两个数据点之间的时间差记为 T , $(T/\Delta t)$ 表示这两个点之间缺失的数据个数。设在时间戳 T_i 采集到的数据为 X_i ,相邻下一个时间戳 $T_{i+\Delta t}$ 采集到的数据为 $X_{i+\Delta t}$ 。根据式(1),可以计算出这两个时间点中间时刻 T_{i+1} 的插补数值:

$$X_{i+1} = \frac{1}{2}(X_{i+\Delta t} + X_i) \quad (1)$$

除此之外,为使数据适配本文所使用的预训练分类模型,在将轨迹转换为图片之后,要将图片尺寸转换为224×224的尺寸。同时,为了增加数据集的多样性,还需将数据进行随机翻转、归一化等数据增强处理操作。

2.1.2 运动特征提取与分布统计

本文结合飞机ADS-B数据的特点,选择速度、加速度和航向变化率^[10]3个属性作为轨迹的运动特征,不仅丰富了轨迹的语义表达,也为后续图像化建模奠定更具判别力的基础。

将包含 n 个轨迹点的一段轨迹表示为如下的矩阵形式:

$$D = \begin{bmatrix} v_1 & \cdots & v_n \\ a_1 & \cdots & a_n \\ c_1 & \cdots & c_n \end{bmatrix}, \quad a_i = \frac{v_{i+1} - v_i}{\Delta t}, \quad c_i = \frac{h_{i+1} - h_i}{\Delta t} \quad (2)$$

式中: D 表示轨迹矩阵; v_i 、 a_i 、 c_i ($i = 1, 2, \dots, n$)分别表示整段轨迹中第 i 个轨迹点的速度、加速度以及航向变化率; h_i 为第 i 时刻航向角。

对3个属性分别进行归一化处理,将各自的取

值区间分别均分为 50 个子区间,统计各子区间内每个属性的出现次数。之后,计算其占总次数的比例,得到特征分布。

$$D' = \begin{bmatrix} v'_1 & \cdots & v'_n \\ a'_1 & \cdots & a'_n \\ c'_1 & \cdots & c'_n \end{bmatrix} \quad (3)$$

式中: D' 为轨迹的特征矩阵; $v'_i, a'_i, c'_i (i = 1, 2, \dots, n)$ 分别表示第 i 个轨迹点的速度、加速度以及航向变化率在各子区间的出现次数。

为验证特征分布的有效性,选取运动模式差异显著的直升机与民航机轨迹进行对比分析。如图 2 所示,民航机的速度分布整体向更高值区间偏移;加速度方面,两类机型因飞行平稳均集中在低值区域,但直升机在高加速度区间仍出现少量分布,暗示其机动需求;航向变化上,民航机受固定航线约束而波动较小,直升机航线灵活导致航向变化频繁且范围更大,差异尤为明显。




图 2 两种机型的运动特征分布

2.2 轨迹图像构建

本节提出一种基于运动特征的 RGB 编码算法,将生成的速度、加速度与航向变化率 3 种运动特征映射至 RGB 色彩空间,实现轨迹运动状态的可视化表达,如图 3 所示。

首先,对式(2)矩阵的每个特征维度进行线性归一化,并将其原始取值区间映射至 $[0, 255]$ 的整数范围,以适配标准 RGB 色彩空间的分量表示。归一化过程由式(4)给出,确保各特征在色彩编码中具有可比性和一致性。

$$F_i^{\text{norm}} = \text{round} \left(\frac{F_i - F_{\min}}{F_{\max} - F_{\min}} \cdot 255, 0 \right) \quad (4)$$

式中: $\text{round}(\cdot)$ 表示取整函数; F_i 代表某轨迹点的特定特征值; $F_{\min}$ 和 $F_{\max}$ 分别为该特征在整个数据集中的最小值与最大值。随后,将归一化后的速度、加速度、航向变化率特征值,分别对应赋予 RGB 色彩空间中的红色(R)、绿色(G)、蓝色(B)通道分量,从而使得每一个轨迹点均获得一个由其 3 要素运动状态唯一确定的 RGB 色彩值,即 $(R, G, B) = (v', a', c')$ 。此编码算法使同一条轨迹在时序上能呈现连续而显著的色彩渐变,直观地刻画其运动状态的动态变化;同时,轨迹本身的几何形态仍保持各异。色彩与形状的双重编码相辅相成,使轨迹的语义表达更具针对性,可视化结果如图 4 所示。





图 3 RGB 色彩空间示意图



(a) 轨迹 1 (b) 轨迹 2 (c) 轨迹 3

图 4 运动状态变化轨迹图

2.3 微调预训练 ResNet 模型

本文策略以在 ImageNet 上预训练的 ResNet18 模型为基础,充分利用其在大规模图像数据中学习到通用视觉特征,同时面向飞行轨迹图像这一特定任务进行适配,构建适用于机型分类的深度识别模型。

在具体实现上,本文系统分析了网络各层特征的可迁移性,采用“冻结底层、解冻高层”的渐进式微调策略。保留前端卷积层的权重以维持对边缘、纹理等低层通用特征的提取能力,仅对靠近输

出的第4卷积层及全连接层进行解冻与优化,使模型更专注于学习轨迹形状与运动特征融合图像中的高层语义信息。同时,将原 ImageNet 分类头替换为适配3类机型的新分类头,并以较低学习率进行训练,以促进模型快速收敛并避免过拟合。

该策略兼顾特征复用与领域适配。冻结底层可防止小样本条件下冗余参数更新带来的过拟合风险。解冻高层有助于模型捕捉与轨迹—运动联合分布高度相关的判别性特征。实验结果表明,该策略在测试集上取得了72.0%的最高分类准确率,显著优于仅微调全连接层或微调所有层等其他策略,验证了其在提升小样本机型识别性能与收敛速度方面的有效性。

图5、图6分别展示了残差块结构及 ResNet18 模型的整体架构。表1列出各层输入输出维度的变化,为模型设计提供了可视化与数据支持。




图5 残差块结构图




图6 ResNet18 结构图

表1 特征提取网络模型参数及维度变化

模块名称	输出维度
输入数据	224×224×3
7×7 conv	112×112×64
最大池化	56×56×64
两个残差模块1	56×56×64
两个残差模块2	28×28×128
两个残差模块3	14×14×256
两个残差模块4	7×7×512
平均池化	7×7×512
全连接层	3

3 实验与分析

本节首先介绍实验条件与数据集,而后通过设计多组对照实验,评估所提方法的性能与可靠性。实验包括不同网络层微调策略的对比、运动特征有效性的验证、模型复杂度影响的探究、数据规模效应的测试以及方法普适性的研究。最终,在多个指标上证明本文方法在小样本场景下的优

越性与鲁棒性。

3.1 实验条件与数据

实验所用硬件条件及软件框架详见表2。

表2 实验条件

设备	参数
工作站名称	ThinkStationP920
内存	64 GB
CPU	64 核 2.1 GHz
显卡	RTX-5000, 16 GB
操作系统	Windows 10(x64)
编程语言	Python 3.7.10
学习框架	PyTorch 1.5.1

实验数据来源于 OpenSky 网站提供的 ADS-B 公共数据集,为2021年1~5月在纬度20°~40°和经度-100°~80°区域内每小时的全球飞行轨迹数据,主要数据结构如表3所示。

表3 ADS-B数据样例

名称	含义	示例
Latitude	飞机的纬度(WGS 84 坐标系)	35.051 788 33°
Longitude	飞机的经度(WGS 84 坐标系)	-90.351 954 87°
Velocity	飞机对地速度	144.786 514 4 m/s
Heading	飞机相对于地理北方顺时针方向角度	288.434 948 8°

3.2 实验过程

所有训练数据均被转换为图像,其中,运动特征以颜色变化的形式进行编码。共使用3 000张图像作为训练集,600张图像作为测试集。

3.2.1 不同微调策略对比

首先,为了探索不同微调策略的有效性,在 ResNet18 模型上分别进行以下实验,训练集数量为3 000。实验1:仅微调全连接层;实验2:微调全连接层与卷积层4;实验3:微调全连接层与卷积层3、4;实验4:微调全连接层与卷积层2、3、4;实验5:微调所有层;实验6:重新训练所有层。实验结果如表4所示。

实验结果表明:1)仅微调预训练模型的全连接层参数,模型并没有得到充分的训练。因原始预训练模型所使用的 Image 1 000 图片数据集与本文所使用的数据集相比有较大差异,因此,卷积层特征提取性能较差,分类准确率仅为63.7%。2)微调全连接层和卷积层4参数,分类精度达到72%,相比于其他微调策略有明显优势。因卷积层4提取的是训练数据的特定特征,且其参数具有相对

独立性,微调它们可以更好地提取本轨迹训练集的特征,从而取得更优的分类性能。3)微调全连接层及卷积层 3、4 的参数,模型性能略有下降(70.8%)。这是因为在预训练模型中,卷积层 3 的参数仍具备一定的普适性,通过 ImageNet 大数据训练得到的参数对于提取通用特征性能已经较好,使用本文所用数据集微调反而会造成性能下

降。4)微调全连接层及卷积层 2、3、4 层参数,仅冻结第 1 层卷积层参数,相比于上一步模型性能略有提升(71.5%)。这是因为卷积层存在相互依赖性,在本实验场景下,卷积层 2、3 之间对于特征提取具有连续性,需要共同参与训练。5)重新训练与微调所有层的方法,由于数据量过小,不足以支撑模型训练,准确率均在 69% 左右。

表 4 在 ResNet18 模型上进行不同微调策略实验结果对比

实验	模型参数					数据类型	准确率/%	F1 值/%	精确率/%	召回率/%
	卷积层 1	卷积层 2	卷积层 3	卷积层 4	全连接层					
1	冻结	冻结	冻结	冻结	微调	彩色	63.7	63.2	63.5	63.7
2	冻结	冻结	冻结	微调	微调	彩色	72.0	71.9	71.8	72.0
3	冻结	冻结	微调	微调	微调	彩色	70.8	70.5	70.4	70.8
4	冻结	微调	微调	微调	微调	彩色	71.5	71.3	71.2	71.5
5	微调	微调	微调	微调	微调	彩色	69.3	69.5	69.6	69.3
6	重训	重训	重训	重训	重训	彩色	69.0	67.9	68.2	69.0

通过实验对比可得,在小样本的情况下,仅微调全连接层和卷积层 4 参数能取得较好的分类精度,分类性能如图 7 和图 8 所示。本次实验选取了运动特征差异显著的 3 种典型机型用于分类任务,分别为直升机(H1T)、大型民航客机(L1T)与军用战斗机(L2J)。




图 7 微调全连接层混淆矩阵




图 8 微调卷积层 4 参数分类性能

3.2.2 模型性能评估与实验结果可靠性验证

为系统评估模型性能并验证实验结果的可靠性,设计了如下对照实验。

1)运动特征有效性验证:将包含运动信息的原始 RGB 轨迹图像替换为灰度图像。实验结果表

明,在灰度数据集上,分类准确率由 72% 下降至 68.2%,同时 $F1$ 值、精确率与召回率均有所降低。证实了包含联合运动特征的轨迹图像对提升分类精度至关重要。

2)模型复杂度影响:将基础预训练模型替换为 ResNet34 和 ResNet50。结果显示,随着模型复杂度(层数)增加,各项性能指标均呈现下降趋势。具体而言,分类准确率分别降至 71.2% 和 70.7%, $F1$ 值降至 70.5% 和 70.1%,精确率仅为 70.5% 和 70.0%,召回率分别降至 71.2% 和 70.7%。表明在小样本数据集条件下,增加模型复杂度不仅未能提升分类精度,反而导致性能下降。

3)数据增强与迁移学习验证:在最优训练参数基础上,通过翻转、平移等变换将训练集样本量增加至 9 000。实验结果显示,各项指标提升显著,证明增加训练数据量能够有效微调并训练出精度更高的分类模型,有力验证了迁移学习的有效性。

上述所有对照实验的详细实验参数配置以及结果如表 5 所示。

为直观评估融合迁移学习与联合运动特征的轨迹分类方法的效果,本文采用 t-分布随机邻域嵌入(t-Distributed Stochastic Neighbor Embedding, t-SNE)对模型提取的特征进行降维可视化分析^[11]。输出特征的可视化分布如图 9 所示。结果表明,在未训练状态下,不同类别目标的轨迹特征高度混杂、难以区分;经训练后,模型在特征空间中能较好地分离 3 类飞机。

表5 实验结果

实验	模型参数						数据类型	训练集数量	准确率/%	F1值/%	精确率/%	召回率/%
	模型类别	卷积层1	卷积层2	卷积层3	卷积层4	全连接层						
1	ResNet18	冻结	冻结	冻结	微调	微调	彩色	3 000	72.0	71.9	71.8	72.0
2	ResNet18	冻结	冻结	冻结	微调	微调	黑白	3 000	68.2	68.2	68.2	68.2
3	ResNet34	冻结	冻结	冻结	微调	微调	彩色	3 000	71.2	70.5	70.5	71.2
4	ResNet50	冻结	冻结	冻结	微调	微调	彩色	3 000	70.7	70.1	70.0	70.7
5	ResNet18	冻结	冻结	冻结	微调	微调	彩色	9 000	75.6	75.8	76.0	75.6

为进一步探究模型决策依据,本节采用类激活映射(Class Activation Mapping, CAM)技术。实验结果如图10所示。结果表明,网络的高响应区域与人眼关注区域(人眼判别时倾向于关注轨迹复杂度高、运动特征变化显著(如颜色渐变)及方向突变(高机动性)的区域)高度吻合,表明模型能自主聚焦于轨迹的关键判别部位,从而进一步验证了本文训练方法的正确性与有效性。




图9 输出特征可视化分布




图10 CAM热力图

3.2.3 方法普适性研究

为验证本文方法在小样本、低信息密度场景下的普适性,选用另两类异构神经网络架构——轻量化网络(MobileNet v2)^[12]以及经典卷积网络(AlexNet)^[13]进行迁移学习对比实验。不同模型用本文方法训练后的准确率结果见图11。




图11 不同模型用本文方法训练后的准确率对比

如图11所示,使用本文方法训练的 AlexNet 与 MobileNet 模型均达到了较好的分类准确率。实验进一步证明了在样本数据量小以及小信息量的情况下,本文方法能取得较好的效果,验证了其普适性。

3.2.4 与现有研究成果比较

将本文方法和现有研究成果在识别准确率上进行比较,结果如表6所示。本文方法识别准确率达到 75.6%,相比 Transformer^[14]提升了 11 个百分点,相比图像处理 CNN 方法提升了 15.3 个百分点,可见本文方法在解决机型识别问题上有一定的优势。

表6 与现有研究成果的对比结果

方法	准确率/%
Transformer ^[14]	64.6
LSTM	62.8
CNN	60.3
iTransformer ^[15]	70.0
TimesNet ^[16]	69.2
TrajFormer ^[17]	67.4
本文方法	75.6

同时,为深入探究模型性能,本文进行如下的横向对比实验:直接使用原始轨迹数据,输入至 iTransformer、TimesNet 和 TrajFormer 等先进序列模型进行分类,识别准确率分别为 70.0%、69.2% 和 67.4%。结果表明,尽管直接利用轨迹序列可实现基线识别性能,但本文采用的从轨迹中提取抽象运动特征并与视觉特征融合的策略,能够更有效挖掘数据中的判别性信息,从而获得更优性能。

4 结束语

本文提出了一种融合迁移学习与运动特征的机型分类识别方法。首先,进行数据清洗并提取原始轨迹中的运动特征以挖掘轨迹数据中的隐含自然冗余信息;其次,运用 RGB 算法构建轨迹特征

图像;最后,基于预训练的 ResNet18 架构,利用迁移学习进行模型微调,实现对 ADS-B 轨迹的机型高精度识别。为验证模型可靠性,本文进行了一系列对比实验,相较于仅使用原始轨迹图像或从头训练的分类模型,本文方法使 ResNet18 的机型分类准确率提升至 75.6%。在小样本数据集条件下,该方法的识别准确率显著优于现有研究成果。

参考文献:

- [1] PEDROCHE D S, AMIGO D, GARCÍA J, et al. Architecture for trajectory-based fishing ship classification with AIS data[J]. *Sensors*, 2020, 20(13):No.3782.
- [2] HUANG H G, HONG F, LIU J, et al. FVID: fishing vessel type identification based on VMS trajectories[J]. *Journal of Ocean University of China*, 2019, 18(2):403-412.
- [3] ENDO Y, TODA H, NISHIDA K, et al. Deep feature extraction from trajectories for transportation mode estimation[C]//*Proceedings of the Advances in Knowledge Discovery and Data Mining*. Cham, Switzerland: Springer, 2016:54-66.
- [4] KONTOPOULOS I, MAKRI S A, TSERPE S K. A deep learning streaming methodology for trajectory classification[J]. *ISPRS International Journal of Geo-Information*, 2021, 10(4):250.
- [5] CHEN X, LIU Y C, ACHUTHAN K, et al. A ship movement classification based on Automatic Identification System (AIS) data using Convolutional Neural Network[J]. *Ocean Engineering*, 2020, 218:No.108182.
- [6] LU S C, XIA Y. Dual supervised autoencoder based trajectory classification using enhanced spatio-temporal information[J]. *IEEE Access*, 2020, 8:173918-173932.
- [7] 王哲,张静,李磊,等.基于“Four-hot”编码和 Transformer-LSTM 模型的船型识别方法[J].*信息工程大学学报*, 2021, 22(6):756-763.
- [8] HE X T, LI Q, WANG R Z, et al. A spatio-temporal feature trajectory clustering algorithm based on deep learning[J]. *Electronics*, 2022, 11(15):2283.
- [9] GE C L, ZHANG J, DU J P, et al. K-M LLM-pro: physics-guided cross-modal adaptation for fine-grained spatio-temporal trajectory classification[J]. *PLoS One*, 2025, 20(10):No.0334412.
- [10] 叶帅男.基于深度卷积网络的交通方式识别[D].成都:西南交通大学,2018:241-247.
- [11] LAURENS V D M, HINTON G. Visualizing data using t-SNE[J]. *Journal of Machine Learning Research*, 2008, 9:2579-2605.
- [12] 李磊,张静,王哲.基于航迹特征和深度神经网络 MobileNet 的舰船分类识别方法[J].*信息工程大学学报*, 2021, 22(6):743-749.
- [13] CORTÉS E, SÁNCHEZ S. Deep learning transfer with AlexNet for chest X-ray COVID-19 recognition[J]. *IEEE Latin America Transactions*, 2021, 19(6):944-951.
- [14] YENDURI G, RAMALINGAM M, SELVI G C, et al. GPT (generative pre-trained transformer): a comprehensive review on enabling technologies, potential applications, emerging challenges, and future directions[J]. *IEEE Access*, 2024, 12:54608-54649.
- [15] LIU Y, HU T G, ZHANG H R, et al. iTransformer: inverted transformers are effective for time series forecasting[DB/OL]. (2023-10-10) [2025-12-22]. <https://arxiv.org/abs/2310.06625>.
- [16] WU H X, HU T G, LIU Y, et al. TimesNet: temporal 2D-variation modeling for general time series analysis[DB/OL]. (2022-10-05) [2025-12-22]. <https://arxiv.org/abs/2210.02186>.
- [17] LIANG Y X, OUYANG K, WANG Y W, et al. TrajFormer: efficient trajectory classification with transformers[C]//*Proceedings of the 31st ACM International Conference on Information & Knowledge Management*. Atlanta GA USA. New York: ACM, 2022:1229-1237.

(编辑:邵 华)