

# 基于改进 ResNet50 模型的体育图像分类

王立宁<sup>1</sup>, 蔡旭东<sup>2</sup>

(1. 长春师范大学 体育学院, 长春 130032; 2. 长春师范大学 计算机科学与技术学院, 长春 130032)

**摘要:** 针对体育图像分类任务中图像内容复杂、动作姿态多变以及背景干扰较大等问题, 提出一种基于改进 ResNet50 模型的体育图像分类算法。首先, 在残差结构内部嵌入挤压和激励模块, 以自适应增强关键通道特征, 提升特征表达能力; 其次, 在此基础上引入特征金字塔网络, 实现多尺度特征的有效融合, 增强模型对不同尺寸目标的感知能力; 最后, 通过全局平均池化与全连接层完成分类预测。实验结果表明, 该方法的分类准确率较传统 ResNet50 模型约提高 5%, 充分体现了其在应对复杂动作与多变背景时的稳健性和优越性。实验结果不仅验证了该方法的有效性和可行性, 且为体育视频分析、智能运动训练等相关领域的应用提供了更可靠的技术支撑与实践参考。

**关键词:** 深度残差网络; 体育图像分类; ResNet50 模型; 注意力机制; 多尺度特征融合  
**中图分类号:** TP391.4 **文献标志码:** A **文章编号:** 1671-5489(2025)06-1655-08

## Sports Image Classification Based on Improved ResNet50 Model

WANG Lining<sup>1</sup>, CAI Xudong<sup>2</sup>

(1. Physical Education Institute, Changchun Normal University, Changchun 130032, China;  
2. College of Computer Science and Technology, Changchun Normal University, Changchun 130032, China)

**Abstract:** Aiming at the problem of complex image content, diverse action postures, and significant background interference in the task of sports image classification, we proposed a sports image classification algorithm based on an improved ResNet50 model. Firstly, a squeeze-and-excitation module was embedded within the residual structure to adaptively enhance key channel features and improve feature expression capability. Secondly, on this basis, a feature pyramid network was introduced to achieve effective fusion of multi-scale features, and enhance the model's perception ability of objects at different scales. Finally, classification prediction was performed through global average pooling and fully connected layers. Experimental results show that the classification accuracy of the proposed method is about 5% higher than that of the conventional ResNet50 model, fully demonstrating its robustness and superiority in handling complex actions and diverse backgrounds. The experimental results not only validate the effectiveness and feasibility of the proposed method, but also provide more reliable technical support and practical reference for applications in sports video analysis, intelligent sports training and other related fields.

**Keywords:** deep residual network; sports image classification; ResNet50 model; attention mechanism; multi-scale feature fusion

体育图像在媒体传播、智能分析、赛事管理等领域应用广泛。如何从海量图像中快速、准确地识

别并分类不同类型的体育场景、项目和动作,对构建智能体育信息系统、提升用户检索效率和观赛体验有重要意义<sup>[1]</sup>。然而,体育图像分类面临多重挑战:首先,体育动作姿态复杂多变,难以捕捉单帧图像的关键特征;其次,背景如光照、场地等干扰问题普遍存在,易影响模型判断;再次,运动员动作变化和遮挡频繁,增加了特征提取难度;最后,目前高质量数据集的标注仍是人工标准,标注成本高<sup>[2]</sup>且易出现错误。

早期体育图像分类方法利用人工分类,在图像数量较少时效果较好,但随着图像数量的增加,人工分类不仅效率低、成本高,且很难保证一致性和准确性。应对上述问题,传统图像处理方法逐渐被引入,例如基于颜色<sup>[3]</sup>、纹理和形状<sup>[4]</sup>等低层特征的分类算法。但这类方法对图像的语义理解能力有限,难以有效应对动作姿态复杂、背景变化显著的体育图像。近年来,随着深度学习技术,尤其是卷积神经网络(convolutional neural network, CNN)的兴起<sup>[5]</sup>,为体育图像分类提供了新方法。通过端到端的学习机制,模型可准确提取图像中的高层语义特征,从而提升分类的准确性和鲁棒性。利用深度学习进行图像分类已成为当前该领域研究的主流方向。

随着深度学习技术的迅猛发展,人工智能已成为计算机视觉领域的核心研究方向,并在体育图像分类任务中取得了显著突破。传统方法如支持向量机<sup>[6]</sup>、K近邻<sup>[7]</sup>及早期的神经网络,主要依赖人工设计的低层图像特征(如颜色、纹理、形状),在处理背景简单、小规模数据时有一定效果,但面对大量数据、结构复杂的体育图像时能力有限。卷积神经网络等深度学习模型则凭借端到端的特征学习能力,大幅度提升了分类的准确性。Li等<sup>[8]</sup>提出了一种结合残差网络与微调技术的体育图像分类方法,通过“网络手术”对模型进行调整,使其能更好地适应特定的体育动作数据,从而提升分类性能。但该方法在面对姿态更复杂多变的体育图像时,分类的准确率有所下降。Niu<sup>[9]</sup>提出了一种基于轻量级双流融合神经网络的体育动作识别方法,融合了浅层多尺度网络与深层残差网络,兼顾了局部细节的敏感性与全局特征的提取能力,同时有效减少了模型参数。但在追求轻量化的同时,削弱了复杂动作变化的敏感性。Gao等<sup>[10]</sup>设计了改进的残差网络架构,采用双分支与密集连接的神经网络结构,可有效解决高动态、低分辨率等体育视频分类的挑战。但其关键帧提取机制仍不太精准,易导致识别误差。Zhou等<sup>[11]</sup>则将深度神经网络与新型金枪鱼群优化(NTSO)算法相结合,用于从原始图像中提取高级特征并优化网络超参数,在准确率、召回率等指标上性能优异。但在处理如光照变化<sup>[12]</sup>、背景干扰<sup>[13]</sup>等复杂环境下的体育图像时,模型鲁棒性仍有待提升。

深度学习模型在体育图像分类任务中展现出优异性能,但仍面临诸多挑战<sup>[14]</sup>。例如,不同运动项目之间可能存在相似的动作姿态<sup>[15]</sup>和背景环境,运动员在高速运动过程中易出现图像模糊<sup>[16]</sup>、遮挡<sup>[17]</sup>等问题,这些因素都对模型的判别能力提出了更高要求。因此,如何在提升分类精度的同时增强模型对复杂<sup>[18]</sup>、多变场景的适应能力,仍是该领域目前研究的重点<sup>[19]</sup>。因此,本文提出一种基于改进 ResNet50 的体育图像分类算法。该算法先在残差结构内部引入挤压与激励(squeeze-and-excitation network, SE)模块后,再引入特征金字塔网络(feature pyramid network, FPN)模块,采用全局平均池化结合全连接层进行分类预测,以进一步加快网络收敛速度并提升分类的准确率。本文主要贡献如下:

1) 针对不同体育图像分类设计通道注意力网络,在残差结构内部引入了挤压与激励模块,在增强特征表达能力的同时,还保留了原始残差网络在深层特征提取方面的优势,同时抑制了无关或冗余的特征表达;

2) 通过引入特征金字塔网络模块,实现了多尺度特征的有效融合,提升了模型对不同尺度目标的感知能力,构建出兼具高语义信息和高空间分辨率的多尺度特征表示;

3) 在训练过程中引入数据增强与正则化技术(如随机裁剪、翻转等),有效增加了数据多样性,降低了模型过拟合风险,从而提升了模型在实际体育图像分类任务中的鲁棒性。

## 1 网络设计

### 1.1 ResNet 网络模型

深度卷积神经网络近年来广泛应用于图像分类、目标检测和语义分割等任务中。然而,随着网络

层数的不断加深, 模型在训练过程中逐渐突显许多问题, 如梯度消失、梯度爆炸以及性能退化等, 同时也制约了深层网络的有效学习和进一步发展。

针对这些问题, He 等<sup>[20]</sup>提出了残差网络, 如图 1 所示, 输入图像  $x$ , 经过卷积得到输出  $F(x)$ , 通过残差连接, 得到最终输出为  $H(x) = F(x) + x$ . 该构造使信息能在网络中跨层传递, 有效缓解了梯度消失的问题. 残差结构将输入信号绕过卷积层直接传递到输出端, 使网络在学习复杂特征的同时, 仍保留了原始信息的完整性. 通过引入残差连接, 训练网络在加深层数的同时仍保持了较好的收敛性和稳定性. ResNet50 由 50 层网络组成, 通过  $1 \times 1$  和  $3 \times 3$  卷积的组合方式, 在保证模型表达能力的同时, 有效降低了参数规模和计算成本. ResNet50 网络结构列于表 1.




图 1 残差网络结构

Fig. 1 Structure of residual network

表 1 ResNet50 网络结构

Table 1 ResNet50 network structure

层数	卷积层	输出尺寸	网络结构
1	Conv1	$112 \times 112$	$7 \times 7, 64, S=2$ ; $3 \times 3$ 最大池化, $S=2$
3	Conv2_x	$56 \times 56$	$[1 \times 1, 64 \rightarrow 3 \times 3, 64 \rightarrow 1 \times 1, 256]$
4	Conv3_x	$28 \times 28$	$[1 \times 1, 128 \rightarrow 3 \times 3, 128 \rightarrow 1 \times 1, 512]$
6	Conv4_x	$14 \times 14$	$[1 \times 1, 256 \rightarrow 3 \times 3, 256 \rightarrow 1 \times 1, 1024]$
3	Conv5_x	$7 \times 7$	$[1 \times 1, 512 \rightarrow 3 \times 3, 512 \rightarrow 1 \times 1, 2048]$
1	平均池化+全连接	$1 \times 1$	平均池化; FC(1000); Softmax

与传统卷积网络相比, ResNet 网络在多个公开数据集和任务中展现出更强的泛化能力和更高的准确率, 因而被广泛用于各类计算机视觉研究与实际应用中. 考虑到 ResNet50 在深层特征提取方面的优势, 本文选择其作为模型的主干网络, 充分利用其在层级特征建模与稳定训练方面的能力, 为后续分类任务提供更稳定的图像表征, 从而提升网络的整体性能.

### 1.2 本文整体网络结构

本文选择 ResNet50 网络作为主干网络, 在此基础上进行结构性改进, 改进内容如图 2 所示. 先将体育图像尺寸统一调整为  $224 \times 224$ , 然后引入批量归一化(batch normalization, BN)加快网络的收敛速度, 并用 ReLU 激活函数增强网络的非线性表达能力, 为深层网络提供更高的特征提取能力.

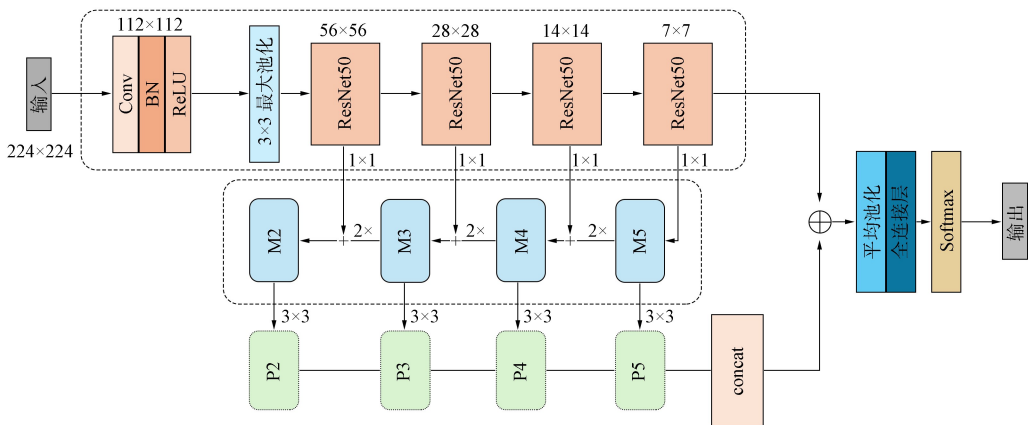


图 2 改进的 ResNet50 网络结构

Fig. 2 Structure of improved ResNet50 network

本文网络由 4 个残差阶段依次组成, 分别包含 3, 4, 6, 3 个残差单元, 在每个卷积层后嵌入了挤压与激励模块, 以实现通道维度上的注意力机制. 该模块通过对每个通道的全局信息建模, 自动学习并

分配不同通道的重要性权重,从而增强对关键特征通道的响应,抑制冗余和无关特征,提高网络对图像中关键信息的感知能力.为增强模型对不同尺度目标的识别效果,在每个残差阶段引入特征金字塔网络,对各级特征图进行自底向上的融合,增强网络对多尺度语义信息的提取与整合能力.最后将融合后的多尺度特征与残差网络的输出逐元素相加,并通过全局平均池化,将特征图的尺寸缩小为 $1 \times 1$ ;然后输入到全连接层(fully connected, FC)中完成特征分类,并通过 Softmax 输出最终的分类结果.本文网络在保持原始 ResNet50 深层语义建模能力的基础上,在特征选择、多尺度融合以及目标感知方面有显著优势,能更有效地完成体育图像的分类任务.

### 1.3 通道注意力结构

在深度卷积神经网络中,通道注意力机制在提升模型性能方面起关键作用.在本文网络中,每个残差卷积块中都引入了 SE 模块,嵌入式地实现通道注意力机制,能有效提升网络对关键信息的表达能力. SE 注意力结构如图 3 所示.




图 3 SE 注意力结构

Fig. 3 SE attention structure

由图 3 可见,该模块主要由压缩(Squeeze)和激励(Excitation)两个阶段组成:首先,在压缩阶段,将尺寸为  $H \times W \times C$  的特征图通过全局平均池化,使每个通道的空间信息压缩为一个尺寸为  $1 \times 1 \times C$  的全局特征描述,从而能捕捉全局上下文关系;其次,在激励阶段,利用两个全连接层构建非线性关系建模网络,学习各通道之间的依赖关系,并输出每个通道的权重系数;最后,将学习到的通道权重与原始特征图逐通道相乘,完成特征重标定,输出尺寸为  $H \times W \times C$  的特征图.通过对各通道进行加权调整,SE 模块能自适应地增强对有判别性通道特征的响应,同时抑制无关或冗余的特征表达.计算过程如下:

$$U_C = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W X_C(i, j), \tag{1}$$

$$s = \sigma(W_2 \cdot \delta(W_1 \cdot z)), \tag{2}$$

$$X_C = s_C \cdot U_C, \tag{3}$$

其中  $W$  表示特征图的宽度,  $H$  表示特征图的高度,  $X_C(i, j)$  表示通道  $C$  上位置  $(i, j)$  的特征值,  $U_C$  表示通道  $C$  的全局平均池化结果,  $\sigma$  表示 Sigmoid 激活函数,  $W_1, W_2$  分别表示全连接层  $FC_1$  和  $FC_2$  的权重矩阵,  $\delta(\cdot)$  表示 ReLU 激活函数,  $X_C$  表示加权后的通道特征图.

在改进的 ResNet50 网络中引入 SE 模块,如图 4 所示,不仅能提升模型对图像中关键区域的关注能力,还可以增强特征表达,为后续的多尺度特征融合和分类任务提供更稳定和高效的特征基础.

### 1.4 特征金字塔网络

本文网络在每层引入特征金字塔网络提升模型对多尺度目标的检测与分类能力.如图 5 所示,FPN 采用自顶向下的路径结构和横向连接机制,将高层特征信息传递至低层特征图,并与其进行融

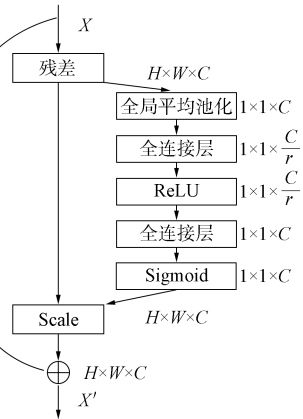


图 4 SE-ResNet50 模块结构

Fig. 4 SE-ResNet50 module structure

合, 进而构建出兼具高语义信息和高空间分辨率的多尺度特征表示. FPN 先基于主干网络提取出多个




图 5 FPN 网络结构

Fig. 5 FPN network structure

不同尺度的中间特征图(记为 $M_2, M_3, M_4, M_5$ ), 这些特征图经过 SE 模块的通道注意力增强后, 通过  $1 \times 1$  卷积对各层特征图进行通道维度对齐, 并采用逐层上采样与低层特征图进行横向融合操作, 最终生成融合后的多尺度特征图(记为  $P_2, P_3, P_4, P_5$ ), 计算过程如下:

$$P_l = \text{Conv}_{1 \times 1}(M_l) + \text{Upsample}(P_{l+1}), \quad (4)$$

其中  $M_l$  表示主干网络的第  $l$  层特征图,

$\text{Conv}_{1 \times 1}(M_l)$  表示对特征图  $M_l$  做  $1 \times 1$  卷积,  $P_l$  表示金字塔特征,  $\text{Upsample}$  表示上采样操作. 该过程不仅可有效增强浅层特征的语义表达能力, 还保留了其空间细节信息. 本文网络通过引入 FPN 模块, 能更好地适应体育图像中目标尺度多变及结构复杂等特征.

## 2 实验与分析

### 2.1 实验环境

实验基于 Python 深度学习框架, 采用 Windows10 操作系统, GPU 为 NVIDIA3080, CPU 为 Intel i7, RAM 为 16 GB.

### 2.2 数据集

实验所用数据集来源于 Kaggle 上的体育图像分类数据集(<https://www.kaggle.com/datasets/gpiosenka/sports-classification>), 先将这些图像用重复检测算法扫描以去除重复并防止训练、测试和验证数据集间的溢出. 为增强训练集的多样性, 本文采用数据增强技术, 包括随机裁剪、水平翻转及颜色变换. 将所有图像尺寸统一调整为  $224 \times 224 \times 3$ , 并转换为 JPG 格式. 数据集由来自 100 个体育类别的图像组成, 其中训练集有 7 840 张图像, 验证集中有 1 680 张图像, 测试集有 1 680 张图像. 图 6 为该数据集中的部分图像示例.



图 6 实验数据集中部分图像示例

Fig. 6 Examples of some images in experimental dataset

### 2.3 参数设置与评价指标

实验的 ResNet50 网络采用随机梯度下降(stochastic gradient descent, SGD)优化算法. 初始学习率为 0.01, 权重衰减系数为 0.01, 模型数据批大小为 32, 训练轮次为 100 轮.

由于体育图像样本间存在数量不均衡现象, 直接使用整体准确率可能无法全面反映模型在各类别

上的真实性能,因此,本文选择平均准确率(mean accuracy, MA)和  $F_1$  值作为主要评估指标,以更客观地衡量模型在各类别上的分类性能.平均准确率通过对各类别的分类准确率取平均,能有效缓解类别不平衡带来的评价偏差; $F_1$  值则综合考虑了模型的精确率和召回率,在衡量模型对少数类样本的识别能力方面有更高的鲁棒性,从而为模型在复杂多类别体育图像分类任务中的综合性能提供更具代表性的评价.各指标计算公式分别为

$$MA = \frac{1}{C} \sum_{i=1}^C \frac{TP_i}{TP_i + FN_i}, \quad (5)$$

$$F_1 = \frac{2 \times TP}{2 \times TP + FP + FN}, \quad (6)$$

$$Recall = \frac{TP}{TP + FN}, \quad (7)$$

其中  $C_i$  代表第  $i$  类体育图像的总样本数,TP 表示该类被正确分类的样本数,FN 表示被错误分类为其他类的样本数,FP 表示被错误分类的样本数,TN 表示被正确分类为其他类的样本数.

## 2.4 实验对比及分析

为验证本文模型优于传统卷积神经网络及现有的分类网络模型,将本文模型与多个先进模型进行对比,并对其进行全面评估.实验结果列于表 2.

表 2 不同网络在体育图像分类数据集上的指标对比

Table 2 Comparison of metrics of different networks on sports image classification dataset

网络模型	平均准确率	召回率	$F_1$ 得分
VGG16 <sup>[21]</sup>	90.86	89.34	89.62
ResNet34 <sup>[22]</sup>	91.12	90.75	91.73
ResNet50 <sup>[23]</sup>	92.26	91.23	91.89
DenseNet169 <sup>[24]</sup>	93.73	91.96	93.08
MobileViT <sup>[25]</sup>	95.59	92.47	93.46
本文	96.61	93.58	94.82

由表 2 可见,本文网络模型在各项指标上均优于对比模型,在准确率方面表现尤为突出.VGG16 网络模型由于结构相对简单、深度较浅,因此难以有效捕捉体育图像中复杂的局部和全局特征,分类的准确率有待提升.ResNet 系列网络模型通过引入残差连接机制,有效增加了深层网络的特征表达能力,但随着网络深度的提升,同样也会导致梯度消失等问题,对特征信息较小的体育图像分类存在误差.DenseNet169 网络模型则依赖密集连接机制实现特征的高效复用,虽能准确提取有效特征,但同样也导致整体网络模型的冗余和较高的计算成本.MobileViT 网络模型则倾向于轻量化设计,将卷积神经网络的局部建模能力与视觉 Transformer 的全局建模优势相结合,在保持较低复杂度的同时取得了良好性能.但在面对图像中复杂动作、图像背景噪声多时,尤其是不同体育运动项目运动员相似的体态,会存在分类错误的结果.而本文网络模型在准确率、召回率和  $F_1$  得分方面均取得了更优性能:与基准模型 ResNet50 相比,准确率约提升 4.35 个百分点,较现有主流的 MobileViT 方法约提升 1.02 个百分点;召回率比 VGG16 网络模型约提升 4.24 个百分点;在  $F_1$  得分方面,分别较基准模型 ResNet50 和 MobileViT 网络模型约提升 2.93, 1.36 个百分点.不同网络在体育图像分类数据集上的指标对比如图 7 所示.上述实验结果充分表




图 7 不同网络在体育图像分类数据集上的指标对比

Fig. 7 Comparison of metrics of different networks on sports image classification dataset

明, 本文模型在体育图像分类任务中具有更强的判别能力和泛化性能.

### 2.5 消融实验

为验证本文卷积神经网络中各模块的有效性和必要性, 特别是通道注意力模块和特征金字塔结构在模型性能提升中的贡献, 选用 ResNet50 作为基准模型, 并在此基础上采用增量的方式逐步引入不同模块. 在体育图像分类数据集上进行分组实验, 系统性的评估各模块对模型整体性能的影响. 消融实验设置如下: 第一组实验使用原始 ResNet50 网络; 第二组在其基础上引入注意力机制; 第三组引入特征金字塔结构; 第四组实验同时集成注意力机制与特征金字塔模块. 实验结果列于表 3. 由表 3 可见, 引入的每个模块对模型性能都有一定提升, 尤其在准确率和  $F_1$  得分方面表现明显.

表 3 不同模块在体育图像分类数据集上的消融实验结果

Table 3 Results of ablation experiment of different modules on sports image classification dataset

网络模型	平均准确率	召回率	$F_1$	%
ResNet50	91.12	91.63	91.73	
ResNet50+SE	93.08	92.31	92.56	
ResNet50+FPN	94.92	93.22	93.96	
本文	96.61	93.58	94.82	

综上所述, 针对体育图像分类任务中存在的图像特征复杂、不同体育项目图像存在相似等问题, 本文提出了一种融合注意力机制与特征金字塔结构的改进型卷积神经网络. 本文模型的主要框架是残差网络, 通过在 ResNet50 网络模型中引入挤压激励模块, 能有效自适应地增强对通道特征的响应, 同时抑制无关或冗余的特征表达; 再引入金字塔网络模块, 构建出兼具高语义信息和高空间分辨率的多尺度特征表示. 通过在多个经典网络结构上的实验对比和消融实验分析, 验证了本文改进方法在准确率与鲁棒性方面优势明显. 结果表明, 本文方法在多个评价指标上均优于现有主流模型, 展现了良好的泛化能力与应用潜力.

### 参 考 文 献

[1] JOSHI K, TRIPATHI V, BOSE C, et al. Robust Sports Image Classification Using InceptionV3 and Neural Networks [J]. *Procedia Computer Science*, 2020, 167: 2374-2381.

[2] PODGORELEC V, PEČNIK Š, VRBANČIČ G. Classification of Similar Sports Images Using Convolutional Neural Network with Hyper-parameter Optimization [J]. *Applied Sciences*, 2020, 10(23): 8494-1-8494-24.

[3] HUANG P. Sports Image Classification and Application Based on Visual Attention Analysis [C]//2021 IEEE Asia-Pacific Conference on Image Processing, Electronics and Computers (IPEC). Piscataway, NJ: IEEE, 2021: 1191-1195.

[4] LIU X C. Comparison of Four Convolutional Neural Network-Based Algorithms for Sports Image Classification [C]//2023 International Conference on Data Science, Advanced Algorithm and Intelligent Computing (DAI 2023). [S.l.]: Atlantis Press, 2024: 178-186.

[5] ZHANG Y M, HOU X C. Application of Video Image Processing in Sports Action Recognition Based on Particle Swarm Optimization Algorithm [J]. *Preventive Medicine*, 2023, 173: 107592-1-107592-7.

[6] ESKOFIER B, OLESON M, DIBENEDETTO C, et al. Embedded Surface Classification in Digital Sports [J]. *Pattern Recognition Letters*, 2009, 30(16): 1448-1456.

[7] JAVED A, MALIK K M, IRTAZA A, et al. A Decision Tree Framework for Shot Classification of Field Sports Videos [J]. *Journal of Supercomputing*, 2020, 76: 7242-7267.

[8] LI Q L, LEI J C, REN C A, et al. Research on Sports Image Classification Method Based on SE-RES-CNN Model [J]. *Scientific Reports*, 2024, 14(1): 19087-1-19087-10.

[9] NIU Z W. A Lightweight Two-Stream Fusion Deep Neural Network Based on ResNet Model for Sports Motion Image Recognition [J]. *Sensing and Imaging*, 2021, 22(1): 26-1-26-16.

[10] GAO T H, ZHANG M, ZHU Y F, et al. Sports Video Classification Method Based on Improved Deep Learning

- [J]. *Applied Sciences*, 2024, 14(2): 948-1-948-13.
- [11] ZHOU Z T, ZHANG H Q, EFFATPARVAR M. Improved Sports Image Classification Using Deep Neural Network and Novel Tuna Swarm Optimization [J]. *Scientific Reports*, 2024, 14(1): 14121-1-14121-20.
- [12] JU X M, DU L L. Image Classification and Sports Dance Biomechanics Analysis Based on Load Balancing Algorithm [J/OL]. *International Journal of System Assurance Engineering and Management*, (2023-08-24) [2024-11-12]. <https://doi.org/10.1007/s13198-023-02100-1>.
- [13] HSU Y L, CHANG H C, CHIU Y J. Wearable Sport Activity Classification Based on Deep Convolutional Neural Network [J]. *IEEE Access*, 2019, 7: 170199-170212.
- [14] SUMBUL G, DE WALL A, KREUZIGER T, et al. BigEarthNet-MM: A Large-Scale, Multimodal, Multilabel Benchmark Archive for Remote Sensing Image Classification and Retrieval [Software and Data Sets] [J]. *IEEE Geoscience and Remote Sensing Magazine*, 2021, 9(3): 174-180.
- [15] YAN F L, PENG Q P. The Application of Deep Learning in Sports Training [J]. *Scalable Computing: Practice and Experience*, 2024, 25(6): 5302-5312.
- [16] GOCHOO M, AKHTER I, JALAL A, et al. Stochastic Remote Sensing Event Classification over Adaptive Posture Estimation via Multifused Data and Deep Belief Network [J]. *Remote Sensing*, 2021, 13(5): 912-1-912-29.
- [17] XIONG F. Motion Recognition Model of Sports Video Based on Feature Extraction Algorithm [C]//2023 IEEE International Conference on Image Processing and Computer Applications (ICIPCA). Piscataway, NJ: IEEE, 2023: 1629-1633.
- [18] WU J, MO Z Q, GAO X, et al. Artificial Intelligence Assisted Wearable Flexible Sensors for Sports: Research Progress in Technology Integration and Application [J]. *International Journal of Smart and Nano Materials*, 2025, 16(3): 510-548.
- [19] CHEN J, SAMUEL R D J, POOVENDRAN P. LSTM with Bio Inspired Algorithm for Action Recognition in Sports Videos [J]. *Image and Vision Computing*, 2021, 112: 104214-1-104214-8.
- [20] HE K M, ZHANG X Y, REN S Q, et al. Deep Residual Learning for Image Recognition [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2016: 770-778.
- [21] LIU L. Objects Detection toward Complicated High Remote Basketball Sports by Leveraging Deep CNN Architecture [J]. *Future Generation Computer Systems*, 2021, 119: 31-36.
- [22] RAMKUMAR P N, LUU B C, HAEBERLE H S, et al. Sports Medicine and Artificial Intelligence: A Primer [J]. *The American Journal of Sports Medicine*, 2022, 50(4): 1166-1174.
- [23] XIAO L, CAO Y, GAI Y H, et al. Recognizing Sports Activities from Video Frames Using Deformable Convolution and Adaptive Multiscale Features [J]. *Journal of Cloud Computing*, 2023, 12(1): 167.
- [24] ZHANG Q Y, ZHANG X Y, HU H S, et al. Sports Match Prediction Model for Training and Exercise Using Attention-Based LSTM Network [J]. *Digital Communications and Networks*, 2022, 8(4): 508-515.
- [25] LI L, WEI Y, XIANG S Z. Infrared Thermal Image Monitoring Based on Artificial Intelligence Application in the Prevention of Sports Injuries in Aerobics: Computational Thermal Modeling [J]. *Thermal Science and Engineering Progress*, 2025, 57: 103126-1-103126-9.

(责任编辑:韩 啸)