

一种轻量化空谱双分支Transformer网络用于白细胞偏振高光谱图像分类

杨雨诗^{①②} 晏佳轩^{①②} 谢 奕^{①②} 邱礼佳^③ 黄丹飞^{*①②}

^①(长春理工大学光电工程学院 长春 130022)

^②(长春理工大学中山研究院 中山 528400)

^③(南方医科大学珠江医院潮南医院 汕头 515144)

摘 要: 白细胞类型与形态是血常规分析的关键, 然而传统镜检方法依赖主观经验, 现有深度学习方法在空谱特征建模和计算效率方面仍存在不足。为此, 该文将偏振高光谱成像技术应用于白细胞分析, 提出一种轻量化空谱双分支Transformer网络(LSDBT)用于白细胞偏振高光谱图像分类。该网络通过双分支特征提取模块联合学习局部空间和空间-光谱特征, 并结合轻量化设计降低计算复杂度。结果表明, LSDBT在实现高精度分类的同时兼顾模型轻量化, 验证了偏振高光谱成像在白细胞分类中的应用价值, 为临床辅助诊断提供高效可靠的技术方案。

关键词: 偏振高光谱成像; 白细胞分类; Swin Transformer

中图分类号: O433.4; TP183; R331.1+42

文献标识码: A

文章编号: 1009-5896(2026)12-0001-10

DOI: 10.11999/JEIT260124

CSTR: 32379.14.JEIT260124

1 引言

白细胞是人体免疫系统的重要组成部分, 其数量、形态和分类信息是评估机体健康与疾病状态的关键依据, 在临床诊断与预后评估中具有重要价值^[1]。目前白细胞分类计数依靠全自动血细胞分析仪和人工镜检两种方法^[2]。全自动血细胞分析仪主要基于流式细胞术, 具有操作简单、检测速度快的特点。然而该方法无法获取细胞图像, 在出现毒性变换等情况时, 分类计数的准确性受限, 因此还需要细胞形态学显微镜检查进一步检测^[3]。细胞形态学显微镜检查是由检验医师直接观察细胞形态并依据经验进行判断, 受限于医师的诊断效率且易引入人为误差。为提高白细胞分类的客观性与检测效率, 结合深度学习与计算机视觉技术的自动分析与分类方法已成为当前重要研究方向^[4]。

在白细胞分类任务中, 深度学习方法的性能普遍优于机器学习方法^[5], 但是基于二维图像的研究依赖细胞核形态学及染色特征, 易受到染色条件、主观判断等因素的影响。为克服这些局限, 高光谱成像技术^[6,7]将连续光谱信息与二维空间特征相结合, 形成“图谱合一”的数据结构, 为细胞精细分类提供了丰富的特征基础。针对这类高维信息的建模, 近年来基于Mamba和Transformer的深度学习方法得到了广泛关注。已有研究表明, Mamba架

构可以有效增强高光谱图像长程特征表示能力^[8,9]。Domain Adaptation方法可通过跨域特征对齐等策略提升模型的泛化能力^[10,11]。Transformer凭借自注意力机制在全局上下文建模中的优势, 在高光谱图像分类中展现出良好的应用潜力^[12,13]。

除了光谱和空间信息外, 偏振成像技术^[14]提供与组织微结构、表面形态和各向异性散射特性有关的信息, 目前已在生物医学领域得到广泛探索, 并被用于癌症^[15]及糖尿病创伤^[16]等病症。将偏振成像与高光谱成像技术融合, 可进一步实现对生物组织与细胞的多维度表征。偏振光谱成像技术^[17]为提升复杂生物医学成像任务中的分类与诊断性能开辟了新途径。Ghassemi等人^[18]基于偏振多光谱成像系统定量评估增生性瘢痕的血红蛋白、氧合和微观结构特征。Dremin等人^[19]通过偏振高光谱成像(Polarized Hyperspectral Imaging, PHSI)捕获糖基化诱导的细微变化, 实现了糖尿病相关皮肤并发症的早期评估。

对于在形态和光谱上高度相似的白细胞亚型, 如不同成熟阶段的淋巴细胞, 高光谱图像特征表征区分可能不显著。Zhou等人^[20]首次将偏振高光谱成像技术应用于细胞研究, 表明偏振高光谱成像技术能够增强白细胞结构的可视化效果。尽管这在白细胞分析中展现出一定潜力, 但目前仍缺乏面向偏振高光谱白细胞图像的系统化深度学习分类方法。现有主流网络在处理高维信息数据时具有一定局限性, 如传统卷积神经网络难以建模中长程的光谱依赖, 导致波段相关性建模能力不足, 而Transformer模型尽管具有全局建模能力, 但其计算复杂度高, 阻碍其在高维偏振高光谱数据中的应用^[12]。

收稿日期: 2026-01-30; 改回日期: 2026-06-29; 网络出版: 2026-07-08

*通信作者: 黄丹飞 hdanfei@163.com

基金项目: 国家自然科学基金(62105245)

Foundation Item: National Natural Science Foundation of China (62105245)

针对上述问题,本研究提出一种轻量化空谱双分支Transformer网络(Lightweight Spatial-spectral Dual-Branch Transformer network, LSD-BT),用于实现白细胞偏振高光谱图像端到端分类。通过构建一种双分支特征提取模块,提取局部空间特征与空间-光谱联合特征,并引入基于移位窗口机制的轻量化Swin Transformer骨干,在对全局有效建模的同时降低计算负担。构建基于偏振高光谱显微成像系统的白细胞图像数据集,验证模型的有效性。

2 材料与方法

2.1 偏振高光谱显微成像系统

偏振高光谱显微成像系统主要由显微镜、偏振片和高光谱相机组成,并有电子目镜配合进行观察。高光谱相机(双利合谱, GaiaMicro)采用透射式光栅结构进行推扫式扫描,光谱范围为360.1 nm至1 035.1 nm,分辨率为 5 ± 0.2 nm。显微镜(舜宇, CX40)配有卤素灯光源和多种倍率的物镜,并且透射和反射通用。如图1所示,系统采用透射成像方式,光源发出的光经过起偏器照射到血涂片上,透射光穿过100倍物镜,通过检偏器进入到高光谱相机。

将起偏器设置为 0° ,分别旋转检偏器至 0° , 45° , 90° 和 135° ,对采集到的图像通过下式计算,能够得到斯托克斯矢量的3个分量

$$S_0 = I_H + I_V \quad (1)$$

$$S_1 = I_H - I_V \quad (2)$$

$$S_2 = I_{45^\circ} - I_{135^\circ} \quad (3)$$

其中, S_0 表征光的总强度, S_1 和 S_2 表征线偏振成分。 I_H 和 I_V 分别是水平方向和垂直方向的光强。 I_{45° 和 I_{135° 分别是 45° 和 135° 方向的光强。在获得3个斯托克斯矢量参数后,可以计算出线偏振度(Degree of Linear Polarization, DOLP):

$$\text{DOLP} = \sqrt{S_1^2 + S_2^2} / S_0 \quad (4)$$

偏振高光谱成像系统可以通过提取斯托克斯矢量参数的谱线更好地观察白细胞与光之间的

相互作用,得到的每个参数都是三维数据立方体,包含2个空间维度和1个频谱维度,记作 $X \in \mathbb{R}^{H \times W \times B}$,其中 $H \times W$ 表示空间维度, B 表示频谱维度。数据包含136个波段,尺寸较大且占用大量计算资源。利用主成分分析将频谱维度降至16,最后按照7:3把得到的所有图像划分成训练集和测试集,并通过随机裁剪和旋转等方式进行数据扩充。

2.2 网络模型

本研究提出的LSDBT模型结构如图2所示。数据经预处理后输入到双分支特征提取模块,该模块基于PHSI的数据特征设计,能够提升图像中偏振特征和空间-光谱特征的表达能力。双分支结构通过可调节缩放因子控制融合过程的相对权重,使模型能自适应地平衡两类特征的贡献。然后使用轻量化SwinT进行全局建模,保持上下文信息的有效性,减少计算复杂度。最后利用全局平均池化将特征图转为特征向量,并用全连接层进行分类预测。

2.2.1 双分支特征提取模块

基于Transformer的传统图像分类方法在模型处理过程中主要聚焦于对各通道空间特征的提取与分析。然而,PHSI同时包含细胞形态结构、局部纹理分布以及不同波段之间的相应差异,通过同时利用其空间与光谱维度信息,将更充分挖掘PHSI的内在结构和判别特征,从而提升分类的准确性。双分支特征提取模块包含一个空间分支和一个空间-光谱分支,分别针对PHSI数据的两个维度进行建模,然后通过重塑层将两种特征对齐并融合,最后将融合后的二维特征图展平并进行层归一化,如图3所示。

模块中的空间分支采用 4×4 的卷积核直接作用于每个光谱通道,将局部空间邻域内的像素聚合成高维特征向量,使偏振特性在特征图中的表达能力得到增强。由于该分支独立处理每个光谱通道,因此能够保留完整的空间纹理信息,为后续提供精细的形态学特征。空间-光谱分支采用 $4 \times 4 \times 4$ 的卷积核对三维邻域实行联合下采样处理,随后通过连续的卷积运算进行非线性变换,逐渐提炼出更具判别性的联合特征。该分支能够挖掘不同光谱波段间的相关性与光谱响应,弥补了对光谱间信息依赖不足的问题。空间-光谱分支的输出通过平均池化与空间分支的尺寸对齐,随后引入可调节缩放因子控制两个特征的融合权重。这种设计使模型具有灵活性,能够根据不同任务需求平衡两种信息的贡献,避免固定权重融合带来的信息失衡问题。双分支融合过后,特征图按空间位置进行展平,转换为特征向量,并进行层归一化以稳定训练过程。




图1 白细胞偏振高光谱显微成像系统






图2 LSDBT网络框架



2.2.2 轻量化Swin Transformer

传统的SwinT架构有4个阶段用于分层计算特征图。每一阶段包含两个连续的Block，用于处理不同分辨率的输入，如图2(b)所示，其中包括基于窗口的多头自注意力(Window based Multi-head Self-Attention, W-MSA)、层归一化(LayerNorm, LN)、多层感知机(Multi-Layer Perceptron, MLP)以及残差连接等操作^[21]。W-MSA将输入特征图划分为局部窗口，在每个窗口内独立计算自注意力，从而降低计算复杂度。通过引入基于移位窗口的多头注意力机制(Shifted Window based Multi-head Self-Attention, SW-MSA)，增强非重合窗口之间的特征信息融合，如图4所示。

为保持PHSI分类性能的同时，显著提升计算效率并降低模型复杂度，本文采用一种轻量化SwinT结构，将原始4个阶段精简为2个核心阶段，大幅减少模型参数量，使其具有更低的内存和计算资源需求。连续两个W-MSA和SW-MSA模块共同组成SwinT Block，具体计算公式为



$$\hat{z}^l = \text{W-MSA}(\text{LN}(z^{l-1})) + z^{l-1} \quad (5)$$

$$z^l = \text{MLP}(\text{LN}(\hat{z}^l)) + \hat{z}^l \quad (6)$$

$$\hat{z}^{l+1} = \text{SW-MSA}(\text{LN}(z^l)) + z^l \quad (7)$$

$$z^{l+1} = \text{MLP}(\text{LN}(\hat{z}^{l+1})) + \hat{z}^{l+1} \quad (8)$$

其中， $\hat{z}^l$ 、 z^l 分别表示位于 l 层块中(S)W-MSA模块和MLP模块的输出特征。 $\hat{z}^{l+1}$ 、 z^{l+1} 分别表示位于 $l+1$ 层块中(S)W-MSA模块和MLP模块的输出特征。本研究中的窗口大小设置为7，第1阶段特征维度为96，包含2个SwinT块，采用3头自注意力机

制；第2阶段特征维度为192，包含2个SwinT块，采用6头自注意力机制。

2.3 网络设置

所有模型在Python 3.8的Pytorch环境中编译和训练，Intel(R)Core(TM)i9-10920X CPU @ 3.50 GHz的服务器作为硬件平台，并配备128 GB运行内存和NVIDIA RTX 3090 GPU。网络训练选用AdamW作为优化器，学习率设置为0.000 1，权重衰减为0.05，Batch Size为32，采用早停策略，最大训练轮次为100轮。

2.4 评价指标

为评估网络模型的性能，研究采用总体准确率(Overall Accuracy, OA)、精确率(Precision)、召回率(Recall)、特异性(Specificity)和F1分数(F1-Score)作为评价指标，下式中TP, TN, FP和FN分别表示真阳性、真阴性、假阳性和假阴性的样本数量。

$$OA = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$

$$Precision = \frac{TP}{TP + FP} \quad (10)$$

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

$$Specificity = \frac{TN}{TN + FP} \quad (12)$$

$$F1-Score = \frac{2 \times Precision \times Recall}{Precision + Recall} = \frac{2TP}{2TP + FP + FN} \quad (13)$$

3 结果与讨论

3.1 偏振高光谱成像结果

去除数据的低信噪比波段，保留光谱范围在459.8~705.2 nm的60个波段，并通过主成分分析降维。图5展示了单核细胞、淋巴细胞和中性粒细胞的PHSI平均光谱曲线，表示对应类型在每个波长下的线偏振成分占比，阴影区域为标准偏差。不同类型谱值不同，反映出细胞内组分的选择性吸收和散射不同。在第5~25波段，各类细胞差异显著，在第30~45波段也显示出可分性。因此，利用线偏振度谱线与空间特征相结合的方法可以使不同类别白细胞具有更高的可区分度，能够有效应用在白细胞的分类任务中。

本文采用极化指数^[19](Polarization Index, PI)对计算得到的白细胞偏振高光谱图像进行可视化表示。PI表示DOLP频谱的积分值，并归一化波段数

$$PI = \frac{1}{B} \sum_{\lambda_i=\lambda_{\min}}^{\lambda_{\max}} DOLP(\lambda_i) \quad (14)$$

其中， $\lambda_{\min}$ 和 $\lambda_{\max}$ 分别定义去除噪声波段后光谱范围的边界。将频谱维度归一化后，得到DOLP的平均值，范围为0到1。成像系统采集的数据立方体由类似方法进行可视化，结果如图6所示。白细胞线偏振度图像可以勾勒出白细胞核的纹理特征，包括颗粒、核大小、轮廓、核凝聚度以及表面结构。对单核细胞而言，偏振高光谱成像技术没有在细胞微结构可视化方面展现出一定的优势，可能是由于单核细胞没有分叶情况且核呈现纤细网状，这与中




图5 白细胞线偏振度谱




图6 白细胞偏振高光谱图像可视化结果

性粒细胞的分叶特征和淋巴细胞的致密块状核有所不同。不过偏振高光谱成像技术可以提高单核细胞大细胞核的图像对比度，从而有效识别细胞核的比例及其形状特征。

3.2 分类结果

为了评估模型性能，本文使用训练好的LSDBT网络在测试集上进行测试，整体准确率为99.29%，混淆矩阵如图7所示，各类别评价指标由表1所示。测试集结果表现出模型对这3种类型的白细胞分类结果良好，且具有相对平衡的特征学习能力。

为探究光谱特征在双分支结构中的权重分配对分类性能的影响，在固定其他结构参数的前提下，依次将模型中的缩放因子设置为1至5进行实验分析。缩放因子用于调节空间-光谱分支输出特征的强度，以平衡空间与光谱特征在融合过程中的贡献。从图8的结果可以看出，随着缩放因子增加，模型性能呈现先上升后略微下降的趋势，这说明适当增加空间-光谱特征的权重有助于提升分类性能，但是过大的权重可能导致空间信息被弱化，从而影响分类稳定性。当缩放因子为3时，模型在空间和光谱特征之间可以取得较好平衡。

3.3 消融实验

为系统评估各模块对模型性能的影响，本研究在标准SwinT模型上依次加入轻量化、空间-光谱特征提取模块、双分支特征提取模块进行消融实验，并以OA为评价指标。从表2可以看出，使用标准SwinT网络仅处理图像的空间维度信息，在建模长程依赖方面仍存在优化空间。在此基础上添加了




图 7 混淆矩阵

表 1 LSDBT在3种类型白细胞上的高光谱图像分类结果(%)

	Precision	Recall	Specificity	F1-Score
Monocytes	99.34	99.07	99.67	99.21
Lymphocytes	99.60	99.47	99.80	99.54
Neutrophils	98.95	99.34	99.47	99.14

轻量化设计，尽管准确率略微下降，但轻微的性能损失是可接受的。采用空间-光谱特征提取模块后，总体准确率得到显著提高，这表明在偏振高光谱图像分类任务中，联合空间与光谱信息具有重要的作用，增强了特征判别能力。引入双分支特征提取模块后，OA进一步提高，说明这种双分支结构能缓解单一信息带来的损失或混淆问题，有助于提高分类准确性。表3说明轻量化设计可使模型计算复杂度明显降低，综合两表结果可知，模型轻量化并不会较大地影响模型性能，LSDBT的结构优于未轻量化模型结构，不仅显示出良好的分类性能，还具有较低的计算复杂度。

3.4 对比实验

为验证偏振高光谱成像技术较现有高光谱成像技术在白细胞分类任务中更具优势，本文同时搭建了高光谱显微成像系统，并在同一批样本上创建对应的白细胞高光谱图像数据集进行对照，采用K-最近邻(K-Nearest Neighbors, KNN)、随机森林(Random Forest, RF)和SVM作为分类器，将OA作为评价指标。从表4结果可知，在所有分类器




图 8 不同缩放因子的分类性能比较

表 2 消融实验结果

Swin Transformer	轻量化	空间-光谱特征提取模块	双分支特征提取模块	OA (%)
✓	×	×	×	97.70
✓	✓	×	×	97.66 (−0.04)
✓	×	✓	×	98.77 (+1.07)
✓	×	×	✓	99.34 (+1.64)
✓	✓	✓	×	98.72 (+1.02)
✓	✓	×	✓	99.29 (+1.59)

表 3 模型轻量化前后的计算复杂度

模型	参数量 (M)	GFLOPs	内存大小 (MB)	OA (%)
双分支特征提取+SwinT	28.32	9.10	108.24	99.34
LSDBT	1.42	3.31	5.49	99.29

表 4 高光谱数据集与偏振高光谱数据集分类结果

数据集	模型	OA (%)
偏振高光谱数据集	KNN	93.1
	RF	95.6
	SVM	94.9
高光谱数据集	KNN	91.2
	RF	93.8
	SVM	93.3

上, 偏振高光谱数据集的分类精度均高于高光谱数据集的结果。这说明偏振技术的引入提供有关细胞纹理的独特信息, 优化不同细胞之间的特征表示, 增强不同类别白细胞在特征空间中的区分度。

目前还尚未有研究直接针对白细胞偏振高光谱图像分类, 为验证本文所提的LSDBT模型性能, 本文从高光谱图像分类与白细胞分类这两个相关技术领域选取模型进行对比。所有模型采用5折交叉验证进行评估, 确保结果的可靠性。表5为各模型分类结果, 其中OA是基于5次验证结果的平均值。本文提出的LSDBT实现了相对领先的分类性能, 并且各项指标保持在较高水平。MambaHSI和SGTFormer模型在不同类别之间的表现波动较大, 说明模型容易出现漏诊或误诊, 对于白细胞的识别效果还有待提升。HSIFormer和MACLST均未达到最高水平, 在淋巴细胞类型上的精确率比其他两类低。对比实验结果验证了LSDBT模型在白细胞偏振高光谱图像分类中的可行性和优越性。

为了比较上述方法在白细胞偏振高光谱图像分

类中的特征提取性能, 采用t-分布随机邻域嵌入(t-Distributed Stochastic Neighbor Embedding, t-SNE)方法对进入分类器前的高维特征进行解码。图9展示了LSDBT, MambaHSI, HSIFormer, SGTFormer和MACLST网络最后一个密集层解码的深度特征, 可以直观看出LSDBT网络展示出优越的特征提取能力。每个细胞群体被分配到特征空间不同区域, 并且彼此之间边界清晰, 几乎没有重叠, 这说明LSDBT网络具有很好的类间区分能力。各群体的点分布紧凑、聚集度高, 说明每个类型在特征空间中具有类内一致性, 有利于模型在分类时保持高精度和召回率。对比之下, HSIFormer提取的深层特征虽然也保持较高的分离趋势, 但单个类别特征的聚集不够紧密, 干扰主要来自于淋巴细胞。而MambaHSI, SGTFormer和MACLST的可视化结果出现明显的分布混淆现象, 类别特征分布分散且边界模糊, 在淋巴细胞和中性粒细胞之间产生较多混乱, 这会导致模型准确率低, 无法取得良好的分类结果。

为进一步评估模型的实际应用潜力, 本文对不同模型的计算成本进行了比较, 结果如表6所示。虽然LSDBT的计算成本并非最优, 但其在分类性能与计算效率之间实现了平衡, 能够在参数量和内存占用保持适中的同时取得最高的分类准确率。这说明LSDBT模型能够在保持高总体分类准确率的同时, 占用较低的计算资源, 证明了该模型在白细胞偏振高光谱图像分类任务中具有一定的应用潜力。

表 5 不同模型的分类结果(%)

模型	类别	Precision	Recall	Specificity	F1-Score	OA
本文LSDBT	Monocytes	99.3	99.1	99.7	99.2	99.2 (± 0.1)
	Lymphocytes	99.6	99.5	99.8	99.5	
	Neutrophils	99.0	99.3	99.5	99.1	
MambaHSI ^[8]	Monocytes	99.2	94.9	99.6	97.0	95.4 (± 1.4)
	Lymphocytes	92.8	99.3	96.2	95.9	
	Neutrophils	98.5	96.0	99.3	97.2	
HSIFormer ^[13]	Monocytes	98.9	97.4	99.5	98.2	98.4 (± 0.1)
	Lymphocytes	97.1	99.6	98.5	98.4	
	Neutrophils	99.3	98.2	99.6	98.7	
SGTFormer ^[22]	Monocytes	99.3	97.8	99.6	98.5	97.3 (± 0.3)
	Lymphocytes	97.8	96.7	98.9	97.2	
	Neutrophils	96.1	98.5	98.0	97.3	
MACLST ^[23]	Monocytes	98.5	97.8	99.3	98.2	97.7 (± 0.4)
	Lymphocytes	97.5	98.9	98.7	98.2	
	Neutrophils	98.2	97.4	99.1	97.8	




图9 深层特征的t-SNE可视化

表6 不同模型计算成本分析

模型	参数量 (M)	GFLOPs	内存大小 (M)	OA (%)
本文LSDBT	1.42	3.31	5.49	99.2 (± 0.1)
MambaHSI	0.12	0.70	0.46	95.4 (± 1.4)
HSIFormer	0.53	1.32	2.14	98.4 (± 0.1)
SGTFormer	219.45	13.85	837.13	97.3 (± 0.3)
MACLST	12.70	4.10	48.40	97.7 (± 0.4)

综合上述实验与分析,本研究不仅验证了偏振高光谱成像技术在白细胞分类任务中的优势,还提供了一种轻量可靠的深度学习方法。LSDBT通过双分支结构融合空间与光谱信息,并利用轻量化SwinT有效建模全局与局部特征,实现不同白细胞类别的高区分度和高判别性,保证了特征在同类样本中具有一致性,在保持较低计算复杂度的同时,对白细胞偏振高光谱图像实现更稳定、更准确的分类效果。

4 结束语

本研究提出了一种轻量化空谱双分支Transformer网络用于白细胞偏振高光谱图像分类。这是首次在白细胞分类任务中融合深度学习与偏振高光谱成像技术。通过与高光谱数据集分类结果对比,验证了偏振高光谱成像技术在白细胞分类任务中的优越性。所提出的双分支特征提取模块能够有效提

取空间与空间-光谱信息,并通过轻量化设计显著降低计算复杂度与参数量。LSDBT网络在白细胞偏振高光谱图像分类任务中取得良好的分类结果,且在各细胞类别上均表现出较高分类水平。这不仅为白细胞自动分类提供一种高效可靠的方法,也为偏振高光谱成像在细胞显微分析提供新思路。然而,本方法的适用性局限于高质量的偏振高光谱图像,在成像较差或波段选择不当时,分类性能可能受到影响。未来工作将着重提升模型在不同条件下的稳定性,扩充细胞类别,并探索深度学习与偏振光谱技术在其他医学领域的应用潜力,从而推动临床转化。

数据集与代码声明:

本文使用的白细胞数据集受伦理保护的限制,暂不公开。模型代码已在本刊数据社区开源: <https://www.scidb.cn/detail?dataSetId=4388f39e133047c3b92b760234fcee1f&version=V1&code=j00173>

参 考 文 献

- [1] 林宇晖. 基于人工智能的血常规分析技术在临床应用中的研究进展[J]. 中国冶金工业医学杂志, 2025, 42(4): 384–385. doi: [10.13586/j.cnki.yjyx1984.2025.04.066](https://doi.org/10.13586/j.cnki.yjyx1984.2025.04.066).
LIN Yuhui. Research progress on the clinical application of artificial intelligence-based complete blood count analysis technology[J]. *Chinese Medical Journal of Metallurgical Industry*, 2025, 42(4): 384–385. doi: [10.13586/j.cnki.yjyx1984.2025.04.066](https://doi.org/10.13586/j.cnki.yjyx1984.2025.04.066).
- [2] 阮受杰. 比较全自动血液分析仪与血涂片镜检在血常规检验中的准确性差异[J]. 中国医疗器械信息, 2025, 31(12): 88–90. doi: [10.15971/j.cnki.cmdi.2025.12.018](https://doi.org/10.15971/j.cnki.cmdi.2025.12.018).
RUAN Shoujie. Comparison of accuracy difference between automatic blood analyzer and blood smear microscopic examination in blood routine test[J]. *China Medical Device Information*, 2025, 31(12): 88–90. doi: [10.15971/j.cnki.cmdi.2025.12.018](https://doi.org/10.15971/j.cnki.cmdi.2025.12.018).
- [3] 温晶. 全自动血细胞分析仪联合血涂片细胞形态学在血常规检验中的应用效果[J]. 中国医疗器械信息, 2025, 31(12): 91–93. doi: [10.15971/j.cnki.cmdi.2025.12.017](https://doi.org/10.15971/j.cnki.cmdi.2025.12.017).
WEN Jing. Application effect of automatic hematology analyzer combined with blood smear cell morphology in routine blood tests[J]. *China Medical Device Information*, 2025, 31(12): 91–93. doi: [10.15971/j.cnki.cmdi.2025.12.017](https://doi.org/10.15971/j.cnki.cmdi.2025.12.017).
- [4] ASGHAR R, KUMAR S, SHAUKAT A, *et al.* Classification of white blood cells (leucocytes) from blood smear imagery using machine and deep learning models: A global scoping review[J]. *PLoS One*, 2024, 19(6): e0292026. doi: [10.1371/journal.pone.0292026](https://doi.org/10.1371/journal.pone.0292026).
- [5] WIBAWA M S. A comparison study between deep learning and conventional machine learning on white blood cells classification[C]. 2018 International Conference on Orange Technologies (ICOT), Nusa Dua, Indonesia, 2018. doi: [10.1109/ICOT.2018.8705892](https://doi.org/10.1109/ICOT.2018.8705892).
- [6] 蔡铁珩, 谭美伶, 潘建军, 等. 基于多尺度非对称密集网络的高光谱图像分类[J]. 电子与信息学报, 2024, 46(4): 1448–1457. doi: [10.11999/JEIT230651](https://doi.org/10.11999/JEIT230651).
CAI Yiheng, TAN Meiling, PAN Jianjun, *et al.* Hyperspectral image classification based on multi-scale asymmetric dense network[J]. *Journal of Electronics & Information Technology*, 2024, 46(4): 1448–1457. doi: [10.11999/JEIT230651](https://doi.org/10.11999/JEIT230651).
- [7] XIE Yi, HUANG Danfei, YAN Jiaxuan, *et al.* Integrated laser speckle contrast and multispectral imaging for in vivo multimodal assessment of small intestinal viability[J]. *Journal of Photochemistry and Photobiology B: Biology*, 2025, 272: 113264. doi: [10.1016/j.jphotobiol.2025.113264](https://doi.org/10.1016/j.jphotobiol.2025.113264).
- [8] LI Yapeng, LUO Yong, ZHANG Lefei, *et al.* MambaHSI: Spatial-spectral mamba for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5524216. doi: [10.1109/tgrs.2024.3430985](https://doi.org/10.1109/tgrs.2024.3430985).
- [9] 廖帝灵, 赖涛, 黄海风, 等. LightMamba: 一种轻量级Mamba用于高光谱图形和激光雷达数据联合分类网络[J]. 电子与信息学报, 2025, 47(12): 4937–4947. doi: [10.11999/JEIT250981](https://doi.org/10.11999/JEIT250981).
LIAO Diling, LAI Tao, HUANG Haifeng, *et al.* LightMamba: A lightweight mamba network for the joint classification of HSI and LiDAR data[J]. *Journal of Electronics & Information Technology*, 2025, 47(12): 4937–4947. doi: [10.11999/JEIT250981](https://doi.org/10.11999/JEIT250981).
- [10] DUAN Puhong, JIN Shiyu, LU Xiaotian, *et al.* Domain-adaptive mamba for cross-scene hyperspectral image classification[J]. *IEEE Transactions on Image Processing*, 2026, 35: 1206–1217. doi: [10.1109/TIP.2026.3657209](https://doi.org/10.1109/TIP.2026.3657209).
- [11] MAHDAVIPOUR Z, ALROMEMA N, KHADER A, *et al.* TGDHTL: Hyperspectral image classification via transformer-graph convolutional network-diffusion with hybrid domain adaptation[J]. *Remote Sensing*, 2026, 18(2): 189. doi: [10.3390/rs18020189](https://doi.org/10.3390/rs18020189).
- [12] 赵凤, 耿苗苗, 刘汉强, 张俊杰, 於俊. 卷积神经网络与视觉Transformer联合驱动的跨层多尺度融合网络高光谱图像分类方法[J]. 电子与信息学报, 2024, 46(5): 2237–2248. doi: [10.11999/JEIT231209](https://doi.org/10.11999/JEIT231209).
ZHAO Feng, GENG Miaomiao, LIU Hanqiang, ZHANG Junjie, YU Jun. Convolutional Neural Network and Vision Transformer-driven Cross-layer Multi-scale Fusion Network for Hyperspectral Image Classification[J]. *Journal of Electronics & Information Technology*, 2024, 46(5): 2237–2248. doi: [10.11999/JEIT231209](https://doi.org/10.11999/JEIT231209).
- [13] ALKHATIB M Q and JAMALI A. HSIFormer: An efficient vision transformer framework for enhanced hyperspectral image classification using local window attention[C]. The 14th Workshop on Hyperspectral Imaging and Signal Processing: Evolution in Remote Sensing (WHISPERS), Helsinki, Finland, 2024: 1–5. doi: [10.1109/WHISPERS65427.2024.10876533](https://doi.org/10.1109/WHISPERS65427.2024.10876533).
- [14] ZHOU Ximing, MA Ling, HALICEK M, *et al.* Development of a new polarized hyperspectral imaging microscope[C]. SPIE 11213, Imaging, Therapeutics, and Advanced Technology in Head and Neck Surgery and Otolaryngology, San Francisco, USA, 2020: 1121308. doi: [10.1117/12.2549676](https://doi.org/10.1117/12.2549676).
- [15] SONG Yuan, HUANG Danfei, WANG Tianyi, *et al.* Polarization imaging method for detection of lung cancer based on symmetrical single LCVR[J]. *Journal of Biophotonics*, 2025, 18(3): e202400470. doi: [10.1002/jbio.202400470](https://doi.org/10.1002/jbio.202400470).
- [16] WOESSNER A E, MCGEE J D, JONES J D, *et al.*

- Characterizing differences in the collagen fiber organization of skin wounds using quantitative polarized light imaging[J]. *Wound Repair and Regeneration*, 2019, 27(6): 711–714. doi: [10.1111/wrr.12758](https://doi.org/10.1111/wrr.12758).
- [17] ZHOU Ximing, MA Ling, MUBARAK H K, *et al.* Polarized hyperspectral microscopic imaging system for enhancing the visualization of collagen fibers and head and neck squamous cell carcinoma[J]. *Journal of Biomedical Optics*, 2024, 29(1): 016005. doi: [10.1117/1.JBO.29.1.016005](https://doi.org/10.1117/1.JBO.29.1.016005).
- [18] GHASSEMI P, TRAVIS T E, MOFFATT L T, *et al.* A polarized multispectral imaging system for quantitative assessment of hypertrophic scars[J]. *Biomedical Optics Express*, 2014, 5(10): 3337–3354. doi: [10.1364/BOE.5.003337](https://doi.org/10.1364/BOE.5.003337).
- [19] DREMINE V, MARCINKEVICS Z, ZHEREBTSOV E, *et al.* Skin complications of diabetes mellitus revealed by polarized hyperspectral imaging and machine learning[J]. *IEEE Transactions on Medical Imaging*, 2021, 40(4): 1207–1216. doi: [10.1109/TMI.2021.3049591](https://doi.org/10.1109/TMI.2021.3049591).
- [20] ZHOU Ximing, MUBARAK H K, MA Ling, *et al.* Polarized hyperspectral microscopic imaging for white blood cells on Wright-stained blood smear slides[C]. SPIE 12382, Polarized Light and Optical Angular Momentum for Biomedical Diagnostics, San Francisco, USA, 2023: 1238207. doi: [10.1117/12.2655708](https://doi.org/10.1117/12.2655708).
- [21] LIU Ze, LIN Yutong, CAO Yue, *et al.* Swin transformer: Hierarchical vision transformer using shifted windows[C]. 2021 IEEE/CVF International Conference on Computer Vision (ICCV), Montreal, Canada, 2021: 9992–10022. doi: [10.1109/ICCV48922.2021.00986](https://doi.org/10.1109/ICCV48922.2021.00986).
- [22] DENG Xiangyu, PAN Lihao, and DANG Zhiyan. SGTformer: Improved shifted window transformer network for white blood cell subtype classification[J]. *Journal of Electronic Imaging*, 2024, 33(4): 043057. doi: [10.1117/1.JEI.33.4.043057](https://doi.org/10.1117/1.JEI.33.4.043057).
- [23] Farooque G, Liu Q, Sargano A B, *et al.* Swin transformer with multiscale 3D atrous convolution for hyperspectral image classification[J]. *Engineering Applications of Artificial Intelligence*, 2023, 126: 107070. doi: [10.1016/j.engappai.2023.107070](https://doi.org/10.1016/j.engappai.2023.107070).
- 杨雨诗：女，硕士生，研究方向为计算机视觉与图像处理技术。
晏佳轩：男，硕士生，研究方向为光电检测与图像分析。
谢奕：男，博士生，研究方向为光电检测与图像分析。
邱礼佳：男，检验师，主要从事临床血液学检验工作。
黄丹飞：女，教授，研究方向为计算机视觉与图像处理技术。
- 责任编辑：马秀强

A Lightweight Spatial-Spectral Dual-Branch Transformer Network for Classifying Polarized White Blood Cell Hyperspectral Images

YANG Yushi^{①②} YAN Jiaxuan^{①②} XIE Yi^{①②} QIU Lijia^③ HUANG Danfei^{①②}

^①(College of Optoelectronic Engineering, Changchun University of Science and Technology, Changchun, 130022, China)

^②(Zhongshan Institute, Changchun University of Science and Technology, Zhongshan, 528400, China)

^③(Chaonan Hospital of Zhujiang Hospital, Southern Medical University, Shantou, 515144, China)

Abstract:

Objective White Blood Cell (WBC) classification and morphology are essential in routine blood analysis and provide important information for disease diagnosis and health assessment. Current WBC classification mainly relies on hematology analyzers and manual microscopic examination. Hematology analyzers cannot acquire cellular images, limiting classification accuracy when abnormal cellular characteristics are present, whereas manual microscopic examination depends on operator experience and is susceptible to human error. Although automated WBC classification based on deep learning and computer vision has attracted considerable attention, methods using stained images are sensitive to staining conditions and image quality. In addition, conventional hyperspectral imaging has limited ability to distinguish WBC subtypes with highly similar morphological and spectral characteristics. To address these limitations, this study combines Polarized Hyperspectral Imaging (PHSI) with deep learning and proposes a lightweight classification framework for polarized hyperspectral WBC images, providing an efficient and reliable approach for clinical decision support.

Methods A polarized hyperspectral microscopic imaging system is established to acquire images at multiple polarization angles. Based on Stokes Vector Theory, polarization parameters are calculated to generate

multidimensional data cubes containing both light intensity and polarization-state information. Degree of Linear Polarization (DOLP) images are then computed to construct a PHSI dataset of WBCs. To exploit the multidimensional characteristics of PHSI, a Lightweight Spatial-Spectral Dual-Branch Transformer Network (LSDBT) is proposed. After preprocessing, the input data are fed into a dual-branch feature extraction module that separately extracts local spatial features and joint spatial-spectral features. An adaptive scaling factor is introduced to fuse the two feature streams and balance their contributions, enabling effective utilization of the multidimensional information contained in PHSI. A lightweight Swin Transformer backbone performs effective global feature modeling while reducing computational complexity. Global average pooling and a fully connected layer are used for classification. Model performance is evaluated using Overall Accuracy (OA), Precision, Recall, Specificity, and F1-Score. Ablation studies, comparative experiments, and feature visualization are conducted to validate the proposed method.

Results and Discussions The DOLP spectra and PHSI visualizations of monocytes, lymphocytes, and neutrophils (Figures. 5 and 6) demonstrate different polarization characteristics that reflect the selective absorption and scattering of light by their internal structures. Compared with conventional intensity images, PHSI improves image contrast and provides additional polarization information that enhances discrimination among WBC types. The proposed LSDBT achieves an OA of 99.29% on the test set, with consistently high classification performance across all cell categories (Table 1). Analysis of the adaptive scaling factor shows that classification performance first improves and then decreases slightly as the scaling factor increases, with the optimal value of 3 providing the best balance between spatial and spatial-spectral features (Figure. 8). Ablation experiments (Tables 2 and 3) demonstrate that the dual-branch feature extraction module substantially improves classification performance, whereas the lightweight design greatly reduces computational complexity and model parameters with only a marginal reduction in accuracy. Compared with conventional hyperspectral imaging, the PHSI dataset achieves higher classification accuracy with all evaluated classifiers, indicating that polarization information provides complementary physical features that improve discrimination among WBC types (Table 4). Comparisons with representative methods show that LSDBT achieves the best overall classification performance across multiple evaluation metrics (Table 5). Furthermore, t-SNE visualization (Figure. 9) shows compact intra-class distributions and clear separation among different cell types, confirming the strong discriminative capability of the learned features. Although LSDBT does not have the lowest computational cost among the compared methods, it achieves the best balance between classification performance, model size, and computational efficiency (Table 6).

Conclusions This study proposes a lightweight dual-branch Transformer network for polarized hyperspectral WBC classification. To the best of our knowledge, this is the first study to combine PHSI with deep learning for WBC classification. Comparative experiments with conventional hyperspectral imaging validate the superiority of PHSI for WBC classification. The proposed LSDBT integrates spatial and spatial-spectral information through a dual-branch feature extraction module and performs efficient global feature modeling using a lightweight Swin Transformer backbone. The network maintains high classification performance while substantially reducing computational complexity and model parameters. These results demonstrate that LSDBT provides an accurate and computationally efficient solution for automated WBC classification and supports the application of PHSI in cellular microscopic analysis and clinical auxiliary diagnosis.

Key words: Polarized Hyperspectral Imaging; White Blood Cell Classification; Swin Transformer