arXiv:2601.00286v1 [cs.CV] 1 Jan 2026

迈向基于深度学习和类别不平衡感知策略的皮肤病自动鉴别诊断

Ali Anaissi[1,2],Ali Braytee[1], 黄卫东[1], Junaid Akram[2], Alaa Farhat[1]和华杰[3]

[1] 澳大利亚悉尼科技大学[2] 澳大利亚悉尼大学[3] 中国邵阳学院
ali.anaissi@uts.edu.au, ali.braytee@uts.edu.au, weidong.huang@uts.edu.au, Junaid.Akram@uts.edu.au, aaf261@student.bau.edu.lb steven.hua @mq.edu.au

摘要。随着皮肤疾病日益普遍，而皮肤科医生数量仍然有限，亟需开发智能工具，帮助患者和临床医生及时、准确地诊断皮肤疾病。在本项目中，我们开发了一种基于深度学习的模型，用于皮肤疾病的分类和诊断。通过利用公开可用的皮肤病图像数据集进行预训练，我们的模型能够有效提取视觉特征，并准确分类各种皮肤疾病病例。

在整个项目过程中，我们不断改进模型架构、优化数据预处理流程，并采用有针对性的数据增强技术，以提升整体性能。最终模型基于 SwinTransformer，在 ISIC2019 数据集的八种皮损类别上取得了 **87.71%** 的预测准确率。这些结果表明，该模型有望成为临床医生可靠的诊断支持工具，以及患者的自我评估辅助工具。

关键词： 皮肤病分类、SwinTransformer、BatchFormer、焦点损失、ReduceLROnPlateau

1 引言

皮肤病，尤其是皮肤癌，已成为全球重大健康问题。早期检测和准确诊断对于有效治疗和改善患者预后至关重要。然而，全球范围内获得皮肤科医生诊疗的机会仍然有限，尤其是在主要由全科医生负责皮肤病诊断的地区 [3, 4, 12, 21]。由于时间有限、资源不足且缺乏专业培训，全科医生的诊断准确率可能不尽理想。

因此，先进技术尤其是深度学习的应用，已成为一种很有前景的解决方案，可帮助患者和临床医生更快、更准确地做出诊断决策。在此背景下，我们项目的目标是运用深度学习技术改进皮肤病分类，尤其是应对图像数据有限和类别不平衡等约束。通过将领域知识与最先进的深度学习方法相结合，我们旨在克服当前的局限性并提高诊断准确率，最终助力改善医疗效果。

在本项目中，我们使用了广泛采用的ISIC-2019皮肤病学数据集，并探索了模型架构和数据增强方面的创新。对于深度学习模型，我们实现了Swin Transformer、传统卷积神经网络和集成卷积神经网络模型。在数据增强方面，我们应用了SAM、AutoAugment、弹性变形和傅里叶变换等技术，以提升模型从图像中提取有意义特征的能力。

我们使用Swin Transformer结合这些数据增强技术和优化后的损失函数，取得了最佳性能，在分类任务上的准确率达到87.71%。这一结果表明，该方法在临床环境中支持医师方面具有显著潜力，可提高诊断精度并辅助皮肤病的早期检测。

2 相关工作

由于对准确、高效的皮肤病诊断 [17, 21]的需求不断增加，皮肤病学分类已成为一个重要研究领域。近年来，已建立多个大型数据集，以支持用于此目的的深度学习模型开发，其中ISIC系列、SD-198和HAM10000是应用最广泛的数据集。在这些数据集中，ISIC-2019数据集尤为突出，众多研究已验证了其数据的稳健性和全面性。本研究选择ISIC-2019数据集作为目标数据集，原因在于其在该领域具有广泛的应用和可靠性。

过去几年，各种深度学习模型已应用于皮肤病学图像分类，其中卷积神经网络（CNN）、基于Transformer的模型和多模型集成方法处于领先地位。ResNet、DenseNet 和 MobileNetV2 等卷积神经网络在图像分类任务中始终表现出色。例如，Rodrigues 等人 [15] 提出了一种结合迁移学习与物联网（IoT）系统的皮肤病变分类方法，利用卷积神经网络提高诊断准确率。同样，Gessert 等人 [7] 将迁移学习应用于在 ISIC系列上预训练的卷积神经网络模型，曲线下面积达到令人瞩目的 97.9%。ResNet 模型也经过了广泛测试，Tan 等人 [16] 和 Mishra 等人 [14] 的研究均表明，ResNet152 的表现最佳。

在较新的研究进展中，Transformer模型在皮肤病学分类领域受到了广泛关注。Liu等人 [13] 提出了Swin Transformer，该模型采用带有移位窗口的层次结构，以提高计算效率并捕捉更广泛的上下文信息。这种方法

已在提升皮肤病学图像分类任务的性能方面展现出巨大潜力。Zhou 等人 [20] 进一步将视觉Transformer（ViT）骨干网络与专用模块相结合，从而提高诊断准确率，并在临床皮肤图像诊断中取得了显著的74.5%准确率。此外，Zhang等人 [19],探索的结合宏观与微观图像的多模态方法，也已被证明能够提高诊断效率。

除了成熟的模型之外，其他主流方法也为皮肤病学分类作出了贡献。Srinivasu 等人 [1] 将 Mo- bileNetV2 与长短期记忆网络（LSTM）结构相结合，以改进模型设计。这种组合方法取得了令人瞩目的 87.17% 准确率，在皮肤病变分类中表现出色。同样，Groh 等人 [8] 开发了预训练 CVGG 模型，旨在通过自动化分类系统的部分流程来协助医师，从而改进决策过程，并进一步巩固深度学习在临床皮肤科诊断中的作用。

除了单一模型方法之外，多模型集成也日益流行。例如，Alshahrani 等人 [2] 将 DenseNet121 、 MobileNet 和 VGG19 的特征组合成一个高维特征矩阵，并通过 t-SNE 降维后取得了 88.79% 的准确率。同样，Gessert 等人 [7] 采用 EfficientNet、SENet 和 ResNeXt 模型的组合进行软投票，进一步提高了分类准确率和鲁棒性。

皮肤病学分类面临的持续挑战之一是数据集中的类别不平衡问题，这可能会影响模型性能。Yao 等人 [18]通过开发 MWNL（改进加权负损失）方法解决了这一问题。该方法为代表性不足的类别赋予较高的损失权重，从而增强模型对难分类或稀有类别的关注。这种方法显著降低了类别不平衡的影响，使皮肤病诊断模型更加均衡、准确。

总的来说，最先进的深度学习模型与大型数据集的结合
，
以及多模型集成和缓解类别不平衡等创新方法，推动了皮肤病学分类领域的发展。持续推进这些领域的进步，对于提高皮肤病检测的诊断准确率和可及性至关重要。

3 所提出的框架

为应对皮肤病变数据集类别不平衡的挑战并提升分类性能，我们提出了一种混合框架，该框架基于在 ImageNet-1K 上预训练的 Swin Transformer 架构构建。尽管这一预训练骨干网络提供了良好的起点，但仍需进行领域特定适配，以提升模型在代表性不足的疾病类别上的泛化能力。

为此，我们实施了一系列架构修改，并整合多种技术——包括 BatchFormer、焦点损失以及动态

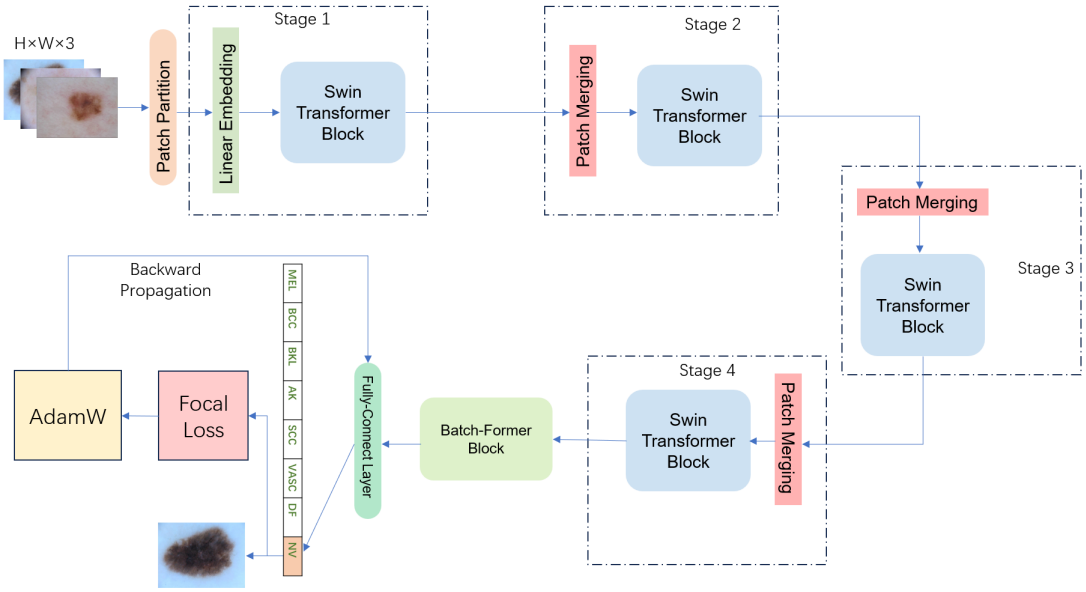


图 1. 基于 Swin-Transformer 的所提出模型结构概览。

学习率调度器（ReduceLROnPlateau）——以提升性能，尤其是尾部类别的性能。模型采用四阶段层次化设计，每个阶段逐步降低空间分辨率，同时增加特征维度，从而能够提取越来越抽象的语义特征。整体结构如图 1 所示。

3.1 Swin Transformer

Ze Liu等人提出的 Swin Transformer [13]，是一种分层视觉Transformer，通过局部自注意力机制提高计算效率。与采用全局注意力、计算开销较大的传统视觉Transformer（ViT）不同，Swin Transformer引入了两种新机制——移位窗口（SW-MSA）和图像块合并，以分层且高效的方式处理图像。

Swin Transformer在自然语言处理领域中Transformer取得成功的基础上，将自注意力的优势与卷积神经网络的分层表征能力相结合。因此，它尤其适用于涉及低分辨率和不同尺寸医学图像的任务。每个SwinTransformer块由两个核心组件构成：基于窗口的多头自注意力（W-MSA）和基于移位窗口的多头自注意力（SW-MSA）。

W-MSA 将注意力计算限制在互不重叠的窗口内，而移位窗口多头自注意力则通过移动划分后的窗

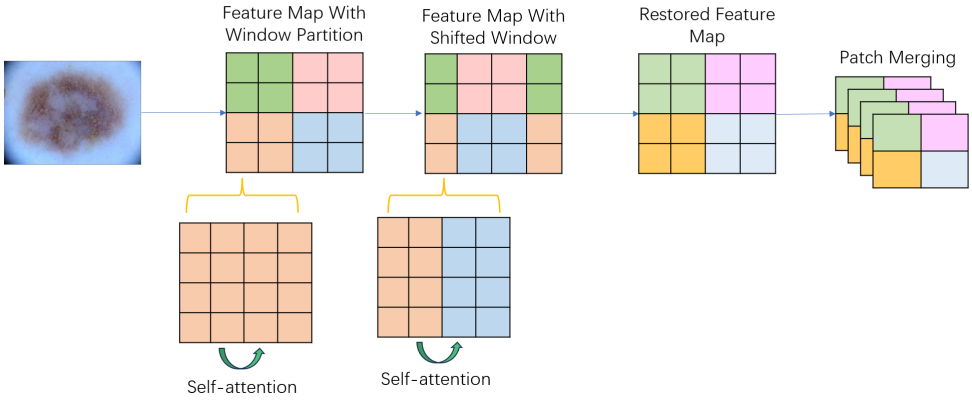


图 2. 窗口多头自注意力 Swin-Tra 中的移位窗口多头自注意力过程 nsformer 模块。

口实现跨窗口的信息交互。这种组合既能学习局部特征，也能学习全局特征，从而提升模型捕捉复杂空间关系的能力。从 W-MSA 转换到移位窗口多头自注意力的完整过程如图 2 所示。

在每个阶段都会采用图像块合并来降低空间分辨率，同时增加特征深度。对于尺寸为 $(H,\ W,\ D)$ 的输入，图像块合并会将空间维度缩减至 $(H/2,\ W/2)$，并将特征深度增至原来的四倍，即 $4D$，使模型能够在较低分辨率下提取更复杂的特征，同时最大限度地降低计算成本。

这种层次结构结合局部注意力和通道维度扩展，使模型具备强大的表征能力，适用于包括皮肤病分类在内的医学影像任务。

3.2 BatchFormer

为解决类别不平衡问题，尤其是罕见疾病样本代表性不足的问题，我们引入了 BatchFormer $[9],$，这是一个通过利用小批次内的样本间关系来增强尾部类别表征学习的模块。

BatchFormer 在批次维度上应用 Transformer 编码器，不仅对单个样本特征进行编码，还对样本间的相似性进行编码。BatchFormer 块的架构如图 3 所示。

这种结构能够实现跨样本梯度传播，即每个样本的梯度都会受到批次中其他样本梯度的影响。如图 4 所示，这种机制能够将知识从头部类别迁移到尾部类别，相当于为代表性不足的类别提供了一种虚拟数据增强。

通过对齐不同类别之间的特征分布，BatchFormer 有助于减轻模型对多数类的偏向，并提升模型对少数类的泛化能力 $[5, 9]$。

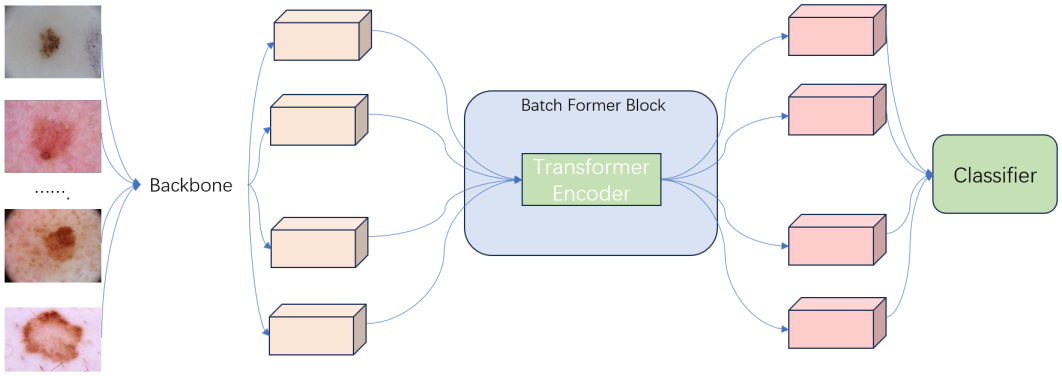


图 3. BatchFormer模块架构。

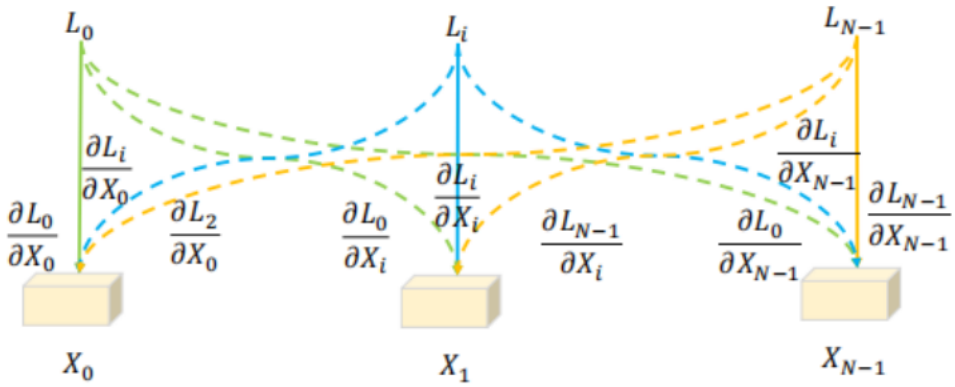


图 4. BatchFormer 中的跨样本梯度传播。

这一机制相当于一种虚拟数据增强，使少数类能够受益于多数类样本产生的丰富梯度，从而提升代表性不足的类别的分类性能。

3.3 面向不平衡学习的焦点损失

为进一步应对数据集中类别不平衡带来的挑战，我们采用了 Lin等人最初提出的焦点损失函数 [11]。与标准交叉熵损失不同，焦点损失会动态调整易分类样本对损失的贡献，并将学习重点放在难以分类的样本上。这对于医学图像分类等场景尤为有益，因为少数类样本往往数量不足且容易被误分类。

焦点损失在标准交叉熵损失中引入了一个调制因子：

$$\mathcal{L}_{\text{focal}} = -\alpha_t (1 - p_t)^{\gamma} \log(p_t) \tag{1}$$

其中：

- p_t 是模型对真实类别的估计概率，
- α_t 是针对类别 t 的加权因子，用于平衡正例和负例，
- γ 是聚焦参数，用于降低分类正确样本的相对损失。

当一个样本以较高置信度被正确分类时（即 p_t 较大），项（$1 - p_t$）$^{\gamma}$ 会变小，从而降低该样本对损失的贡献。相反，对于分类错误或置信度较低的样本，损失仍然较高，迫使模型在训练过程中重点关注这些更困难的样本。

在我们的应用中，焦点损失使模型能够优先从代表性不足且难以分类的样本中学习，这有助于改善对少数类的分类，同时减轻对多数类的过拟合。与传统采样策略或代价敏感学习不同，焦点损失直接重塑损失景观，使其计算效率更高，也更易于集成到现代深度学习框架中。

3.4 使用ReduceLROnPlateau进行学习率调度

为优化训练稳定性和收敛性，我们采用 ReduceLROnPlateau 调度器，根据验证损失进入平台期的情况动态调整学习率。当模型性能停滞时，该调度器会降低学习率，使模型能够在训练后期进一步微调参数。

结合焦点损失，这种方法进一步改善了学习动态。焦点损失促使模型关注难分类的样本，而 ReduceLROnPlateau 则确保学习率得到适当调整，以便进行细粒度更新。二者共同帮助防止过拟合、加快收敛速度，并提升不平衡数据集上的分类性能。

4 实验

4.1 数据集描述与准备

本研究使用 ISIC2019 数据集，这是由国际皮肤影像协作组织（ISIC）提供的公开基准数据集。该数据集包含数千张皮肤镜图像，按不同皮肤病变类别标注，可通过 ISIC 官方档案库获取。

为深入了解数据集并识别潜在的分类挑战，我们对类别分布进行了初步统计分析。

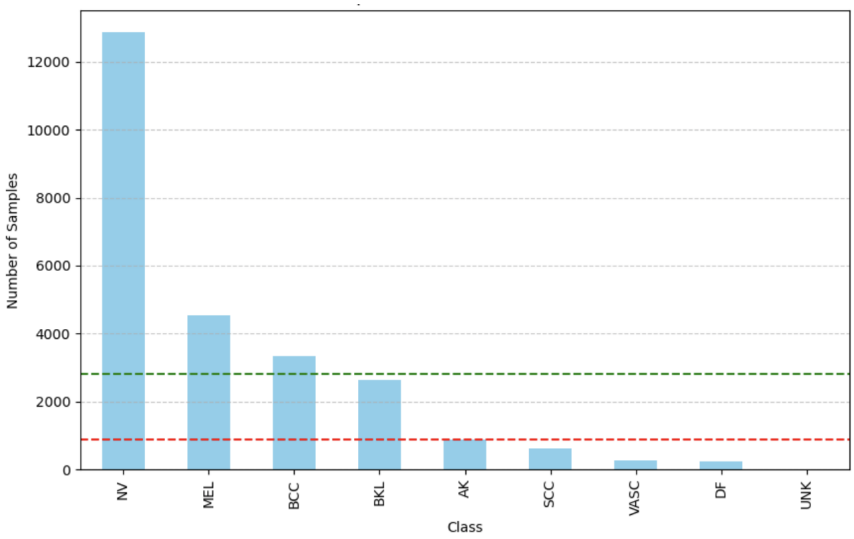


图 5. ISIC2019 数据集中的类别分布。

表 1. 采用和未采用 SAM 预处理时的分类准确率。

模型	准确率
ViT	65.6%
ViT + SAM	62.0%
ResNet	75.6%
ResNet +SAM	73.0%
Swin Transformer	76.6%
Swin Transformer + SAM	70.8%

我们使用 NumPy 计算了每个类别的样本数量，以及相应的均值和中位数。图5所示的分析结果揭示了严重的类别不平衡。例如，“NV”（黑色素细胞痣）类别包含超过 12,000 个样本，而“DF”（皮肤纤维瘤）类别的样本不到 300 个。这种分布不均给训练稳健且公平的分类器带来了重大挑战。因此，我们的方法采用了多种不平衡感知学习策略，包括焦点损失和 BatchFormer。

为准备训练和评估所用的数据集，我们将其划分为三个子集：70% 用于训练，15% 用于验证，15% 用于测试。我们采用分层抽样策略，确保所有子集中的类别分布保持一致，在保留类别不平衡特征的同时，实现公平的模型评估。

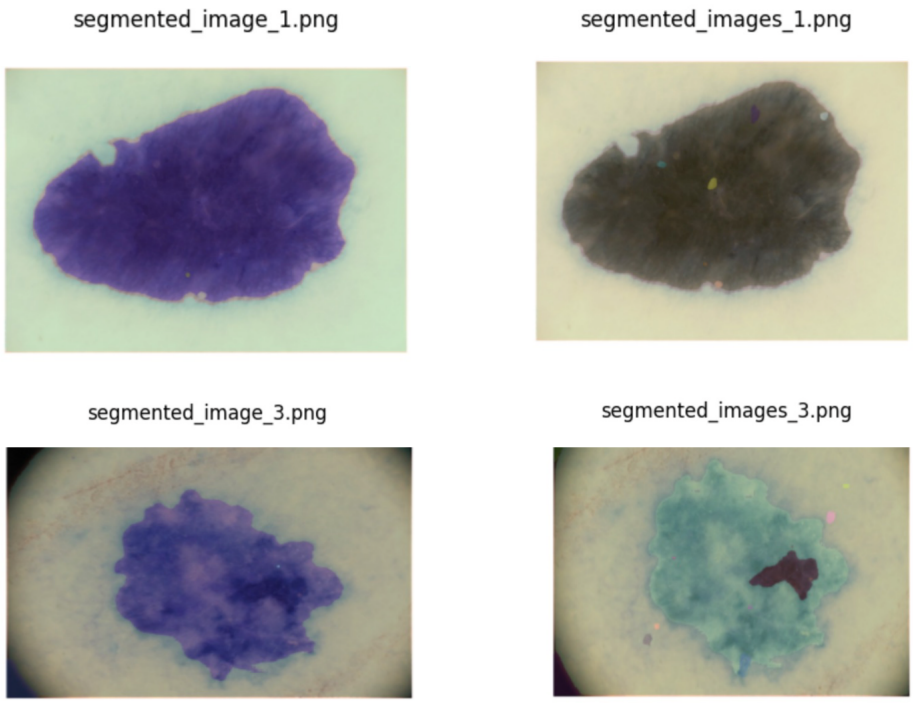


图6. 使用 SAM 生成的病变掩膜示例。

表2. 数据增强后的分类准确率。

模型	准确率
DenseNet	71.53%
DenseNet +AutoAugment	73.87%
Swin Transformer	87.34%
Swin Transformer + 弹性变形 87.71%	

4.2 实验设置

数据预处理与数据增强 为减轻类别不平衡的影响，我们实施了多种数据预处理和数据增强策略。首先，我们尝试使用由 Meta 开发的 Segment Anything Model (SAM) [10]，为每个病灶生成分割掩膜。我们利用这些掩膜，通过突出病灶区域的边界，使其更加清晰。我们的假设是，聚焦于这些分割区域可以突出与病灶相关的特征，从而提高分类准确率。除了分割之外，我们还采用了两种增强技术：

– 弹性变形通过基于高斯的位移场扭曲图像，以模拟病变形状的多样性 [6]。

表3。 ISIC2019 上的模型性能比较。

模型类别	模型	准确率
CNN	DenseNet121-CE	76.47%
	DenseNet121-MWNL	61.37%
	DenseNet121 + 傅里叶Transformer	80.16%
	EfficientNet	80.94%
	加权集成	73.18%
	拼接集成	68.89%
	U-Net	60.52%
	ResNet50 + SimAM	69.18%
Transformer	ViT	80.16%
	Swin Transformer + BatchFormer + 焦点损失 +ReduceLROnPlateau	**87.71%**

– AutoAugment 是一种基于策略的数据增强方法，通过组合应用各种变换（例如旋转、颜色抖动）来丰富训练集。

仅对训练样本少于 2,000 个的疾病类别选择性地应用了弹性变形，以直接解决类别不平衡问题。

5 结果与讨论

我们的研究旨在 Transformer 深度学习框架中融入先进的数据预处理、数据增强和优化策略，以提升皮肤病变分类性能。所提出的系统包含两个核心组成部分：(1) 针对数据集特定挑战定制的预处理与数据增强流程；(2) 基于 Swin Transformer 的分类模型，并通过加入优化模块来提升其在不平衡数据上的表现。

为评估各组成部分的贡献，我们分三个阶段开展实验：评估基于分割的预处理、应用数据增强技术，以及进行模型层面的优化。以下将讨论各阶段的研究结果。

5.1 基于分割的预处理的影响

我们首先研究了将分割作为预处理步骤的影响，并使用 Segment Anything Model (SAM) 生成病变掩膜。这些掩膜用于在皮肤镜图像中分离病变边界；我们的假设是，增强这些区域有助于分类器聚焦于与诊断相关的区域。

然而，我们的实证结果与这一预期相悖。表 1 显示，在应用 SAM 预处理后，所有受测架构（ViT、ResNet 和 Swin Transformer）的准确率均持续下降。这表明，分割过程可能会引入伪影，或遗漏细微但至关重要的

病灶特征，例如颜色多样性、纹理不对称和色素网络——这些特征对皮肤科评估至关重要。

此外，SAM 虽然功能强大，但它是一种通用模型，并未针对皮肤镜图像进行专门微调。这一局限可能导致分割边界不准确，尤其是在病变复杂或形状不规则时，从而引入噪声，而非改善分类器的关注重点。这些观察结果凸显了使用领域专用分割工具，或整合病变感知注意力机制，而不是将通用分割作为预处理步骤的重要性。

5.2 数据增强的有效性

为了解决类别不平衡并丰富特征变异性，我们采用了两种数据增强技术：AutoAugment 和弹性变形。AutoAugment 运用多种变换策略（例如旋转、亮度调整和剪切），使模型能够接触更广泛的类内变化。弹性变形引入空间畸变，以模拟病变形态的自然生物变异。

表2显示，两种增强技术均提升了不同模型的性能。例如，DenseNet 通过 AutoAugment 实现了 2.3% 的准确率提升，而 Swin Transformer 在采用弹性变形进行数据增强后，准确率最高，达到 87.71%。值得注意的是，我们仅对代表性不足的类别应用弹性变形，这表明有针对性地使用该方法有助于在训练过程中有效平衡类别表示。

这些结果证实，合理的数据增强不仅能缓解类别不平衡，还能提升模型鲁棒性，使模型能够更好地适应各种病灶外观，从而增强泛化能力。这在医学影像领域尤为重要，因为现实世界中的变化性很高，若过拟合有限的视觉线索，可能会损害诊断效用。

5.3 模型比较与最终结果

在数据增强带来的改进基础上，我们进一步比较了模型架构，并结合优化策略，以提升分类性能。我们在 ISIC2019 数据集上评估了多种模型，包括传统卷积神经网络和现代基于 Transformer 的架构。表3总结了评估结果。

DenseNet121 和 EfficientNet 等基于 CNN 的模型表现出色，其中 EfficientNet 的准确率达到 80.94%。采用傅里叶Transformer和注意力模块等技术，进一步提升了卷积神经网络的性能。然而，基于Transformer的模型展现出更高的准确率，这可能得益于其对长程依赖和全局模式的建模能力更强。

表现最佳的配置将 Swin Transformer 与 BatchFormer、焦点损失和 ReduceLROnPlateau 相结合，分类准确率

达到 87.71%。Swin Transformer 的层次化设计和移位窗口注意力机制实现了高效的多尺度特征提取，这对于分析细微的病灶纹理和更广泛的形状不对称性至关重要。BatchFormer 通过促进同一小批次中样本之间的表征共享，实现了样本间学习，从而有效提升了对少数类的识别能力。

焦点损失在缓解类别不平衡的影响方面发挥了重要作用：它通过降低简单样本的权重，并在训练过程中更加关注较难分类和误分类的样本。最后，ReduceLROnPlateau 根据验证性能动态调整学习率，确保了更平稳的收敛，并防止过拟合。

总体而言，这些结果验证了所提出的方法是皮肤病变分类的有效解决方案，尤其适用于类别不平衡和异质数据分布的情形。将基于 Transformer 的架构与定制的数据增强和优化策略相结合，为未来的医学图像分析研究提供了有前景的方向。

6 结论

我们的研究结果表明，Swin Transformer 是一种能力出众的皮肤病变分类架构，尤其适用于处理存在显著类别不平衡的大规模数据集。与传统的基于 CNN 的模型相比，Swin Transformer 始终取得更优的结果——最突出的是，与 BatchFormer、焦点损失和 ReduceLROnPlateau 学习率调度器结合时，准确率达到 87.71%。这表明它能够通过层次化自注意力机制有效捕捉局部纹理和全局上下文信息。

然而，尽管 Swin Transformer 表现出色，它并未内置任何可直接处理数据不平衡的机制。此外，该模型使用 ImageNet 等通用数据集的预训练权重进行初始化，这些权重可能并不完全适用于皮肤病分类所用皮肤镜图像的特定特征。

为进一步提升性能，未来研究可着重于使用特定领域的皮肤病学数据集对模型进行微调，以增强其对病灶特异性特征的敏感度。此外，整合更稳健的不平衡感知学习策略，例如动态类别加权损失函数或自适应采样技术，可能有助于提升少数病灶类型的分类性能，并确保各类别的预测更加均衡。

致谢

我们感谢以下每位学生在整个研究过程中付出的辛勤努力、展现的坚韧精神以及所作的承诺：Xinyu Ma、Frank Cheng、Sean Xia、Huiwen Zhao、Yuhao Xiong 和 Yibo Ding。

参考文献

1. Al-Tuwaijari, J.M., Yousir, N.T., Alhammad, N.A.M., Mostafa, S.：用于皮肤癌疾病检测与分类的深度残差学习图像识别模型。Acta Informatica Pragensia **12**(1), 19–31 (2023) 2. Alshahrani, M., Al-Jabbar, M., Senan, E.M., Ahmed, I.A., Mohammed Saif, J.A.：基于整合卷积神经网络模型特征的混合系统，对多类别皮肤镜图像进行分析，以早期检测皮肤病变。Plos One **19**(3), e0298305 (2024) 3. Anaissi, A., Goyal, M., Catchpoole, D.R., Braytee, A., Kennedy, P.J.：基于案例的基因表达数据检索框架。Cancer informatics **14**, CIN–S22371 (2015) 4. Anaissi, A., Kennedy, P.J., Goyal, M.：基于局部主成分的微阵列数据降维。世界科学、工程与技术学院 **53**(2012) 5. Anaissi, A., Kennedy, P.J., Goyal, M., Catchpoole, D.R.：一种用于从微阵列数据中进行基因选择的平衡迭代随机森林。BMC bioinformatics **14**, 1–10 (2013) 6. Chlap, P., Min, H., Vandenberg, N., Dowling, J., Holloway, L., Haworth, A.：深度学习应用的医学图像数据增强技术综述。Journal of Medical Imaging and Radiation Oncology **65**(5), 545–563 (2021) 7. Gessert, N., Nielsen, M., Shaikh, M., Werner, R., Schlaefer, A.：使用结合多分辨率 EfficientNet 与元数据的集成模型进行皮肤病变分类。MethodsX**7**, 100864 (2020) 8. Groh, M., Badri, O., Daneshjou, R., Koochek, A., Harris, C., Soenksen, L.R., Picard, R.：借助深度学习的决策支持系统，跨不同肤色诊断皮肤病。Nature Medicine **30**(2), 573–583 (2024) 9. Hou, Z., Yu, B., Tao, D.：Batchformer：学习探索样本关系，以实现鲁棒表示学习。arXiv预印本 arXiv:2203.01522 (2022)。https://doi.org/10 01522 10 48550 2203 . /arXiv. . . Kirillov, A., Mintun, E., Ravi, N., Mao, H., Rolland, C., Gustafson, L., Girshick, R.：Segment anything。载于：IEEE/CVF国际计算机视觉会议论文集。第 4015–4026 页 (2023) 11. Lin, T.Y., Goyal, P., Girshick, R., He, K., Doll´ar, P.：用于密集目标检测的焦点损失。载于：IEEE国际计算机视觉会议（ICCV）论文集。第 2980 324 12 2988 2017 10 1109 2017 – ( )。https://doi.org/ . /ICCV. . . Liu, Y., Jain, A., Eng, C., Way, D.H., Lee, K., Bui, P., Coz, D.：用于皮肤疾病鉴别诊断的深度学习系统。Nature (2020) 13. Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., Guo, B.：Swin Transformer：使用移位窗口的层次化视觉Transformer。载于：IEEE/CVF国际计算机视觉会议论文集。第 10012–10022 页 (2021) 14. Mishra, S., Imaizumi, H., Yamasaki, T.：通过深度学习解读细粒度皮肤病分类。载于：IEEE/CVF计算机视觉与模式识别会议研讨会论文集。第 0–0 页 (2019) 15. Rodrigues, D.D.A., Ivo, R.F., Satapathy, S.C., Wang, S., Hemanth, J., Reboucas Filho, P.P.：一种基于迁移学习、深度学习和物联网系统的皮肤病变分类新方法。Pattern Recognition Letters **136**, 8–15 (2020)

16. Tan, Z., Lin, J., Chen, K., Zhuang, Y., Han, L.：基于相似性聚类和注意力迁移的皮肤癌图像识别。《X射线科学与技术杂志》**31**(2), 337–355 (2023) 17. Wu, Y., Ji, Y., Lee, S., Akram, J., Braytee, A., Anaissi, A.：用于癌症组织病理学的稳健且可扩展诊断服务的简化群体学习框架。载于：国际计算科学会议。第225–232页。Springer (2025) 18. Yao, P., Shen, S., Xu, M., Liu, P., Zhang, F., Xing, J., Xu, R.X.：针对不平衡小数据集的单模型深度学习，用于皮肤病变分类。IEEE医学成像学报**41**(5), 1242–1254 (2021) 19. Zhang, Y., Hu, Y., Li, K., Pan, X., Mo, X., Zhang, H.：探究基于Transformer的多模态建模对临床医生皮肤疾病诊断的影响：定量分析。《数字健康》**10**, 20552076241257087 (2024) 20. Zhou, Y.J., Liu, W., Gao, Y., Xu, J., Lu, L., Duan, Y., Wang, Y.：一种模仿皮肤科医生、用于临床图像中皮肤疾病精准鉴别诊断的新型多任务模型。载于：国际医学图像计算与计算机辅助干预会议。第202–212页。Springer Nature Switzerland (2023年10月) 21. Zhou, Y., Liu, J., Yang, Z., Liu, T., Meng, X., Zhou, Z., Anaissi, A., Braytee, A.：Vgg-fusionnet：一种基于CT扫描和胸部X射线图像的深度学习特征融合框架，用于COVID-19检测。载于：2022年IEEE国际数据挖掘研讨会（ICDMW）。第1–9页。IEEE (2022)